

НАУКА

**и глобальные вызовы
XXI века**

**ИНТЕЛЛЕКТУАЛЬНЫЕ
СИСТЕМЫ В НАУКЕ И ТЕХНИКЕ**

**ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ
И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА**

Пермь, 2020

Пермский государственный национальный исследовательский университет
Пермский национальный исследовательский политехнический университет
Национальный исследовательский университет «Высшая школа экономики»
Пермский государственный гуманитарно-педагогический университет
Пермский государственный медицинский университет им. академика Е. А. Вагнера
Пермское отделение Научного совета при президиуме РАН
по методологии искусственного интеллекта

**ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ
В НАУКЕ И ТЕХНИКЕ.
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ
И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА**

*Сборник статей по материалам Международной конференции
«Интеллектуальные системы в науке и технике»
и Шестой всероссийской научно-практической конференции
«Искусственный интеллект в решении актуальных социальных
и экономических проблем XXI века»*

(г. Пермь, 12–18 октября 2020 г.)



Пермь 2020

УДК 004.8: 3
ББК 32.813 + 6/8
И868

И868 **Интеллектуальные системы в науке и технике. Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века [Электронный ресурс] : сборник статей по материалам Международной конференции «Интеллектуальные системы в науке и технике» и Шестой всероссийской научно-практической конференции «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века» (г. Пермь, 12–18 октября 2020 г.) / под редакцией Л. Н. Ясницкого ; Пермский государственный национальный исследовательский университет. – Электронные данные. – Пермь, 2020. – 16,7 Мб ; 654 с. – Режим доступа: <http://www.psu.ru/files/docs/science/books/sborniki/iskusstv-intellekt-v-reshenii-akt-problem-xxi-veka.pdf>. – Заглавие с экрана.**

ISBN 978-5-7944-3552-8

В сборнике представлены материалы Международной конференции «Интеллектуальные системы в науке и технике» и Шестой всероссийской научно-практической конференции «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века», которая проводилась 12–18 октября 2020 г. в г. Перми в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века».

Сборник предназначен для научных и педагогических работников, преподавателей, аспирантов, магистрантов, студентов и всех, кто интересуется проблемами и перспективами развития и применения методов искусственного интеллекта.

УДК 004.8: 3
ББК 32.813 + 6/8

*Издается по решению кафедры прикладной математики и информатики
Пермского государственного национального исследовательского университета*

*Сборник подготовлен при финансовой поддержке
Министерства образования и науки Пермского края: Договор Д-26/120
от 27.07.2020, а также гранта РФФИ: № 19-010-00307.*

Статьи публикуются в авторской редакции, авторы несут ответственность за содержание статей, за достоверность приведенных в статье фактов, цитат, статистических и иных данных, имен, названий и прочих сведений

ISBN 978-5-7944-3552-8

© ПГНИУ, 2020

ОГЛАВЛЕНИЕ

ПРИВЕТСТВЕННОЕ СЛОВО	8
ПЛЕНАРНЫЕ ДОКЛАДЫ	10
Ошибки интеллекта, основанного на данных	11
Определение параметров случайных составляющих погрешностей инерциальных датчиков бесплатформенной инерциальной навигационной системы методом Аллана	14
Креативный симбиоз человека и интеллектуального инструмента.....	23
Математическое моделирование и машинное обучение в анализе данных микроволновой радиотермометрии	28
Уравнения динамики манипуляторов с шестью степенями свободы	34
Медицина и искусственный интеллект	45
Медицина и искусственный интеллект глазами пермских ученых.....	51
СЕКЦИОННЫЕ ДОКЛАДЫ	59
Классификация технологий искусственного интеллекта для определения типа гражданско-правовой ответственности.....	60
Нейросетевая модель в подходах к выбору распределения финансовых средств муниципальным учреждениям	66
Применение нейронных сетей для обнаружения фактов курения в системах видеонаблюдения.....	71
Переносимое обучение на основе знаний в компьютерном зрении.....	77
Тестирование алгоритма локализации опухоли при раке молочной железы на результатах моделирования температурных полей.....	88
Нейронные сети и регрессионный анализ в диагностике рака молочной железы	93
Разработка и реализация приложения для генерации мелодий с помощью генетического алгоритма	99
Концепция построения онтологически управляемых нейроинтерфейсов	106
Интеллектуализация тестирования с открытыми вопросами на основе определения семантической близости фраз	112
Применение самоорганизующихся карт Кохонена для анализа базы патентов	116
Экспертная система для автоматического выявления ролей пользователей в социальных сетях на основе нейросетевых технологий.....	118
Ontology Reasoning on Microcontroller Units	127
Особенности проектирования системы контроля регулярных расходов в мобильном приложении.....	133

Компьютерная интеллектуальная система оптимизации адаптивного управления процессами бизнес-планирования.....	139
Система распознавания лиц для сервисного робота	146
Аппарат для переработки пластиковых отходов в филамент для 3D печати ...	152
О мощности критерия нормальности, основанном на разбиении носителя распределения на 2 части, на симметричных альтернативах	155
Исследование способов мониторинга процесса 3d печати	161
Построение модели движения кисти руки на базе микроэлектромеханических сенсоров и алгоритма динамической трансформации временной шкалы.....	165
Analysis of psychological profiles of typical twitter users who actively discuss COVID-19 treatment	171
Значение технологии blockchain для позитивации смарт-контракта в условиях создания нормативного регулирования цифровой среды	179
Программа выбора Парето-оптимальных решений для интеллектуальной системы.....	184
Применение аддитивных технологий для строительной промышленности.....	189
Оценка эффективности подкрепляющих элементов в задаче оптимизации композитной пластины	195
Разработка алгоритма идентификации лиц человека на основе правил золотого сечения.....	200
Проектирование системы мониторинга состояния тросов вантовых мостов методом неразрушающего контроля на основе эффекта виллари.....	205
Применение аддитивных технологий при прототипировании прогрессивного оборудования.....	213
О соотношениях, связывающих кумулянты с центральными моментами, и их применение	217
Прикладной антропоморфизм в сервисной робототехнике.....	223
Моделирование системы иерархического распознавания для предварительного расчёта характеристик процесса.....	228
Адаптивное двухстороннее мультиагентное управление газотурбинного двигателя	233
Нечеткий регулятор состояний.....	240
Прогнозирование стоимости автомобиля на основе его характеристик.....	246
Прогнозирование спроса на аренду велосипедов с помощью нейросетевой модели.....	251
Анализ качества красного вина по его физико-химическим параметрам	259

Предсказание наличия осложнений после операции удаления острого аппендицита	265
Использование цифрового двойника при управлении энергосистемами, включающими аэс или тэс в условиях снижения достоверности данных, поступающих от оборудования	273
Искусственный интеллект глазами интеллектуального обывателя.....	277
Определение уровня демократии в странах методом нейросетевого моделирования	281
Статическое интерполяционное прогнозирование показателей рынка недвижимости с использованием дискретной пространственно-параметрической модели (ДППМ)	289
Создание нейросетевой модели для прогнозирования дорожно-транспортных происшествий	302
Прогнозирование процента голосов, полученного партией в ходе выборов в государственную думу, с помощью нейронных сетей	309
Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости частных домов на примере рынков недвижимости Пермского края.....	320
Возможности прогнозирования продаж компьютерных игр методами искусственного интеллекта	330
Создание интеллектуальной системы на основе нейронной сети, способной анализировать фактические технологические параметры изготовления стержней лопаток авиационных двигателей	343
Прогнозирование места команды в автогоноках «Формула 1» с помощью нейронных сетей	346
Прогнозирование результатов автогонок «Формула 1» с помощью нейронных сетей	354
Усовершенствование искусственного интеллекта в Unity.....	361
Прогнозирование концентрации метана в рабочей зоне угольной шахты на основе рекуррентных нейронных сетей	366
Методы и модели формирования дескрипторов для интеллектуальных систем оценки риска инфекционных заболеваний на основе анализа биоимпеданса зон аномальной электропроводности	371
Нейросетевая система классификации музыкальных инструментов.....	379
Нейросетевая система оценки риска внебольничной пневмонии.....	386
Динамическая нейросетевая система оценки вторичного рынка жилой недвижимости Нижнего Новгорода.....	393
Нейросетевая система оценки стоимости квартир Перми	402

Нейросетевое прогнозирование наличия нервно-психической неустойчивости.....	409
Самоадаптируемая нейросетевая система оценки качества питания человека	420
Прогнозирование пользовательского рейтинга мобильных приложений.....	427
Разработка системы поддержки принятия врачебных решений на основе методов искусственного интеллекта.....	433
Применение нейросетевых технологий в прогнозировании количества поступивших обращений в службу технической поддержки региональной информационной системы в сфере закупок товаров, работ, услуг для обеспечения государственных нужд Пермского края	442
Сравнение методов машинного обучения для прогнозирования оценки студента за учебную дисциплину на основе его предыдущих оценок.....	448
Нейросетевое прогнозирование продаж видеоигр в первую неделю после выпуска.....	455
Прогнозирование продаж группы товаров из ассортимента организации.....	461
Диагностика болезни сердца на основе метода нейронных сетей.....	465
Нейросетевая система прогноза опасных метеорологических условий	471
Использование методов искусственного интеллекта в прогнозировании склонности человека к прокрастинации.....	484
Нейросетевые структуры с латентными переменными в прогнозировании состояния живых систем.....	497
Нейросетевое прогнозирование рейтинга телевизионных передач.....	505
Прогнозирование прочности сплава в зависимости от легирующих добавок..	513
Прогнозирование результатов спортивных событий при помощи нейронных сетей	520
Нейросетевая система оценки стоимости бриллиантов	528
Прогнозирование суицидального поведения	536
Нейросетевая система оценки вероятности выживания пассажира на борту парохода “Титаник”	542
Нейросетевая модель дешифратора электромиосигнала с датчиком мышечной нагрузки.....	549
Нейросетевая система прогнозирования успеваемости учеников	557
Прогнозирование коинтеграции временных рядов на основе нейронных сетей	564
Самоадаптируемая нейросетевая система оценки и прогнозирования мировых кассовых сборов фильма.....	569

Нейросетевое прогнозирование мирового рейтинга фильма и зависимость этого рейтинга от популярности киноленты в социальных сетях.....	582
Нейросетевая система оценки условной прибыли от проката фильма	588
Использование функциональной предобработки зашумленных данных в задачах классификации	595
Прогнозирование занятого места футбольной команды в лиге чемпионов.....	600
Нейросетевая система прогнозирования и анализа посещаемости матчей РФПЛ.....	607
Влияние распространения аддитивных технологий на экологическую обстановку.....	615
Повышение качества обучающего множества нейронной сети методом кластеризации.....	621
Исследование алгоритмов взаимодействующих роботов методом имитационного моделирования.....	626
Риски цифровизации и роботизации для сферы социальной защиты и социального обслуживания в России	633
Нейросетевая система оценки стоимости квартир Москвы.....	643
Анализ резюме кандидатов с использованием нейросетей и экспертных систем для оценки профессиональной пригодности и возможной будущей зарплаты	650

«Думаю, она [Конференция] хорошо отображает тот факт, что ваша Пермская школа и ваша системная деятельность – лучшее, что есть в нашей стране в области многоплановой разработки проблем ИИ.»

Д.И.Дубровский, Сопредседатель Научного совета при президиуме РАН по методологии искусственного интеллекта, д.ф.н., профессор.

ПРИВЕТСТВЕННОЕ СЛОВО

члена Программного комитета конференции, академика Европейской Академии Наук,
Президента Ассоциации Изобретателей Израиля, руководителя Департамента науки Альянса Народов Мира,
профессора Олега Львовича Фиговского (Израиль)

Дорогие организаторы и участники конференции «Интеллектуальные системы в науке и технике», разрешите поздравить Вас с началом работы конференции.

В настоящее время внедрение в жизнь общества методов искусственного интеллекта становится все более и более актуальным, а поэтому отраднo то, что на решение задач построения математических моделей, алгоритмов и программного обеспечения искусственного интеллекта обращают внимание не только в российских столицах, но и в городах, далеких от крупных мегаполисов.

М.В. Ломоносов говорил:

– Богатство России будет прирастать Сибирью.

Пермь – это не Сибирь, а Урал, но и пермские вузы, обладающие хорошим потенциалом, сегодня могут внести значительный вклад в развитие всей российской науки и, в частности, в развитие методов искусственного интеллекта и их использования в промышленности страны.

В Перми существует Пермского отделение научного Совета РАН по методологии искусственного интеллекта, на кафедрах пермских вузов подготовлены кандидаты и доктора наук, чьи исследования посвящены применению методов искусственного интеллекта в решении задач экономики региона. Однако хотелось бы, чтобы о научных результатах исследований пермских ученых знали не только в Пермском крае, но и гораздо шире.

Сегодня исследования по искусственному интеллекту носят, прежде всего, инновационный характер, поэтому уже при постановке научных задач важна, в первую очередь, их принципиальная мировая новизна. К

сожалению, зачастую, российские ученые стремятся повторить зарубежные исследования, что неизбежно влечет присутствие огромного количества конкурентов и не может обеспечить лидерства в сфере искусственного интеллекта. Важно придумывать принципиально новые приложения искусственного интеллекта в социуме.

Разработка методов искусственного интеллекта требует привлечения не только математиков и программистов, но и специалистов из других отраслей науки, поэтому важны исследования педагогов, психологов, философов и т.д., посвященные оценке влияния искусственного интеллекта, как на современное общество, так и общество будущего.

Хорошо то, что секции конференции посвящены, как узкоспециализированным докладам, так и результатам исследований специалистов более широкого, прежде всего, гуманитарного профиля.

Одной из главных задач конференции «Интеллектуальные системы в науке и технике» должен стать отбор именно тех исследовательских проектов в естественных и гуманитарных науках, которые представляют неожиданные постановки научных задач, способных обеспечить приоритет пермских вузов в науке. Я надеюсь, что с этой задачей оргкомитет конференции справится.

Важно также обеспечить всяческую поддержку приоритетным исследованиям.

Но, конечно же, чтобы делать новое, нужно придерживаться принципа познания, сформулированного Ционом Сулиманом и говорящего, прежде всего, о преемственности научных поколений:

– Если тебе нужна новая идея, просто открой старую книгу.

Желаю успешной работы конференции, хороших докладов ее участникам и нестандартных научных идей.

Профессор О.Л. Фиговский, Израиль

ПЛЕНАРНЫЕ ДОКЛАДЫ

ОШИБКИ ИНТЕЛЛЕКТА, ОСНОВАННОГО НА ДАННЫХ

Горбань Александр Николаевич

University of Leicester, UK

Национальный исследовательский Нижегородский государственный университет им. Н. И. Лобачевского, a.n.gorban@le.ac.uk

Настоящий доклад представляет собой краткий отчет о проекте, использующем новый подход к повышению интеллектуальной эффективности искусственного интеллекта. Представлены новые и оригинальные математические подходы к неитеративному исправлению ошибок систем искусственного интеллекта.

Ключевые слова: искусственный интеллект, нейронная сеть, концентрация меры, ошибка, коррекция.

Все системы искусственного интеллекта (ИИ) допускают ошибки. Эти ошибки неожиданны и часто отличаются от типичных человеческих ошибок («нечеловеческие» ошибки). Ошибки ИИ должны быть исправлены без ущерба для существующих навыков и, желательно, без прямого человеческого участия.

Представлены математические основы неразрушающей коррекции ИИ и ряд новых теорем стохастической отделимости [1-3]. Эти теоремы предоставляют новый инструмент для разработки, анализа и оценки методов и алгоритмов машинного обучения в высокой размерности. Они демонстрируют, что в больших размерах и даже для экспоненциально больших выборок линейные классификаторы в их классической форме Фишера достаточно сильны, чтобы отделить ошибки от правильных ответов с высокой вероятностью и обеспечить эффективное построение неразрушающего корректора.

Непрерывное развитие многочисленных автоматизированных систем искусственного интеллекта для интеллектуального анализа данных неизбежно. Хорошо известные продукты искусственного интеллекта, способные хотя бы частично отвечать на вызовы больших данных, уже разработаны такими технологическими гигантами, как Amazon, IBM, Google, Facebook, SoftBank и многими другими. Современные системы искусственного интеллекта для интеллектуального анализа данных потребляют огромные и быстро растущие коллекции разнородных данных.

На сегодняшний день на миллионах компьютеров и гаджетов различных платформ развернуты многочисленные версии этих систем огромных размеров. Присущая данным неопределенность приводит к неизбежным

ошибкам (например, неправильной маркировке, ложным сигналам тревоги, ошибочным определениям, неверным прогнозам и т. д.) систем интеллектуального анализа данных ИИ, которые требуют разумного использования. Успешная работа любой системы искусственного интеллекта диктует, что ошибки должны быть обнаружены и исправлены немедленно и локально в сетях. Однако перенастройка больших систем искусственного интеллекта в режиме реального времени непомерно дорога и даже опасна.

Будущее развитие устойчивых больших систем искусственного интеллекта для анализа больших данных требует создания технологий и методов быстрой неитеративной, неразрушающей и обратимой коррекции систем анализа больших данных и быстрого усвоения новых навыков сетью искусственного интеллекта. Этот процесс должен исключать человеческий опыт, насколько это возможно.

В этом докладе мы представили краткий обзор нового подхода к дополненному ИИ [1-9]. Этот подход сочетает быстрые неразрушающие и неитеративные корректоры ошибок и передачу знаний между ИИ. Некоторые части и версии этой технологии были внедрены и протестированы.

Линейный дискриминант Фишера очень удобен и эффективно разделяет данные для многих распределений в больших размерностях [7,8]. Каскады независимых линейных дискриминантов также очень просты и более эффективны. Мы систематически тестировали линейные и каскадные корректоры с моделируемыми данными и на обработке реальных видеопотоковых данных. Сочетание низкоразмерных нелинейных решающих правил с многомерными простыми линейными дискриминантами является перспективным направлением дальнейшего развития алгоритмов.

Новые теоремы стохастической отделимости показывают, что технология корректоров может быть использована для обработки ошибок в потоках данных с очень общими распределениями вероятностей и далеко от классической гипотезы о независимости и одинаковой распределенности.

Технология дополненного ИИ необходима для предотвращения глубокого падения с текущего пика завышенных ожиданий от ИИ в ущелье обманутых ожиданий.

Благодарности. Доклад подготовлен при поддержке Министерства науки и высшего образования Российской Федерации в рамках мегагранта, проект № 14.Y26.31.0022.

Библиографический список

1. Gorban A.N., Romanenko I., Burton R., Tyukin I.Y. One-Trial Correction of Legacy AI Systems and Stochastic Separation Theorems // Information Sciences. 2019. V. 484. P. 237-254. <https://arxiv.org/abs/1610.00494>
2. Gorban A.N., Tyukin I.Y. Stochastic Separation Theorems // Neural Networks. 2017. V. 94. P. 255-259. <https://arxiv.org/abs/1703.01203>
3. Gorban A.N., Grechuk B., Tyukin I.Y. Augmented Artificial Intelligence: a Conceptual Framework // arXiv preprint. 2018. <https://arxiv.org/abs/1802.02172>.

4. Tyukin I.Y., Gorban A.N., Sofeikov K., Romanenko I. Knowledge Transfer Between Artificial Intelligence Systems // *Frontiers in Neurorobotics*. 2018. V. 12. № 49. <https://arxiv.org/abs/1709.01547>.
5. Gorban, A.N. Tyukin I.Y. Blessing of dimensionality: mathematical foundations of the statistical physics of data // *Phil. Trans. R. Soc. A*. 2018. V. 376. № 2118. <https://arxiv.org/abs/1801.03421>.
6. Tyukin I.Y., Gorban A.N., Green S., Prokhorov D., Fast Construction of Correcting Ensembles for Legacy Artificial Intelligence Systems: Algorithms and a Case Study // *Information Sciences*. 2018. V. 485. P. 230-247. <https://arxiv.org/abs/1810.05593>.
7. Gorban A.N., Golubkov A., Grechuk B., Mirkes E.M., Tyukin I.Y., Correction of AI systems by linear discriminants: Probabilistic foundations // *Information Sciences*. 2018. V. 466. P. 303-322. <https://arxiv.org/abs/1811.05321>.
8. Gorban A.N., Makarov V.A., Tyukin I.Y. The unreasonable effectiveness of small neural ensembles in high-dimensional brain // *Phys. Life Rev*. 2019. V. 29. P. 55-88, <https://arxiv.org/abs/1809.07656>.
9. Gorban A.N., Makarov V.A., Tyukin I.Y., High--Dimensional Brain in a High-Dimensional World: Blessing of Dimensionality // *Entropy*. 2020. V. 22. №1. Paper number 82. <https://arxiv.org/abs/2001.04959>.

ERRORS IN DATA-BASED INTELLIGENCE

Gorban Alexander N.

University of Leicester, UK

Lobachevsky State University of Nizhni Novgorod

a.n.gorban@le.ac.uk

We present a brief report on a project that uses a new systematic approach to improving the intellectual efficiency of AI. New and original mathematical approaches to prompt one-shot correction of errors in artificial intelligence systems are presented.

Key words: artificial intelligence, neural network, measure concentration, error, correction

ОПРЕДЕЛЕНИЕ ПАРАМЕТРОВ СЛУЧАЙНЫХ СОСТАВЛЯЮЩИХ ПОГРЕШНОСТЕЙ ИНЕРЦИАЛЬНЫХ ДАТЧИКОВ БЕСПЛАТФОРМЕННОЙ ИНЕРЦИАЛЬНОЙ НАВИГАЦИОННОЙ СИСТЕМЫ МЕТОДОМ АЛЛАНА

*Злыгостева Мария Павловна, Ахтямова Лариса Финатовна,
Колеватов Андрей Петрович*

Пермская научно-производственная приборостроительная компания, 614990,
Россия, г. Пермь, ул. 25 Октября, 106, m_zlyg@mail.ru

Представлена инженерная методика применения вариации Д. Аллана при идентификации случайных составляющих погрешностей инерциальных датчиков (волоконно-оптических гироскопов и маятниковых акселерометров), входящих в состав бесплатформенных инерциальных навигационных систем (БИНС), выпускаемых на ПАО «ПНППК». Методика предполагает обработку больших объёмов данных, полученных при многочасовых испытаниях БИНС. С целью сокращения времени вычисления вариации Аллана предложено использовать два набора точек времени осреднения. Для доказательства корректности вычислений расчёты вариации Аллана произведены на модельных данных, сгенерированных по заданным вероятностным характеристикам. Показано, что точность оценивания вариации Аллана зависит от количества независимых групп в данных. Приведены результаты обработки экспериментальных данных, полученным при многочасовых испытаниях различных БИНС. Для получения оценок характеристик случайных погрешностей инерциальных датчиков выполняется аппроксимация вариации Д. Аллана обобщённым методом наименьших квадратов. Полученные коэффициенты вариации Д. Аллана используются как характеристики точности инерциальных датчиков и применяются в алгоритмах БИНС в качестве калибровочных коэффициентов для повышения точности выходных параметров навигационных систем.

Ключевые слова: вариация Аллана, оценка, обобщенный метод наименьших квадратов, навигационная система, точность.

Введение

В состав бесплатформенных инерциальных навигационных систем (БИНС) в качестве измерителей параметров движения объекта входят инерциальные датчики – гироскопы и акселерометры. На точность функционирования БИНС существенно влияет структура шумов выходных сигналов инерциальных датчиков. Поэтому работы, связанными с анализом характеристик случайных составляющих погрешностей инерциальных датчиков являются актуальными. Известные традиционные способы

статистической обработки измерений, опирающиеся на определение выборочных оценок средних значений, дисперсий, корреляционных функций и спектральных плотностей [1, 2], как правило, не дают желаемого эффекта из-за сложности структуры шумов инерциальных датчиков. Современным методам идентификации характеристик случайных погрешностей посвящены работы [3-12]. В настоящее время всё большую известность приобретает метод идентификации характеристик структуры шумов, основанный на использовании вариации Д. Аллана. Настоящая работа посвящена особенностям использования этого подхода при обработке больших объёмов измерений, полученных при многочасовых испытаниях навигационных систем.

Описание вариации Аллана

Подробное описание метода вариации Д. Аллана содержится в работах [3-7,10]. Приведем лишь краткое изложение метода, необходимое для понимания результатов работы.

Для случайной последовательности $Y_k(t), k = \overline{1, S}$ вариация Аллана $\sigma_A^2(\tau)$ на интервале осреднения τ , определяется как разница полусредних значений двух соседних групп данных $\overline{Y}_k(t)$ по формуле [7, с. 99]:

$$\sigma_A^2(\tau) = \frac{1}{2 \cdot (G-1)} \cdot \sum_{k=1}^{G-1} (\overline{Y}_{k+1} - \overline{Y}_k)^2, \quad (1)$$

где $G = \frac{S}{D}$ – количество используемых при вычислении групп из потока данных S , D – размер группы. При этом, $\tau = \frac{D}{f_s}$, где f_s – частота опроса измеряемой величины.

В работе [7] показано, что, исходя из известных для инерциальных датчиков основных составляющих случайных погрешностей, аппроксимирующее выражение для вариации Аллана (ВА) $\sigma_A^2(\tau)$ может быть представлена полиномом $p_A^2(\tau)$ в следующем виде:

$$\sigma_A^2(\tau) \approx p_A^2(\tau) = R^2 \cdot \frac{\tau^2}{2} + K^2 \cdot \frac{\tau}{3} + B^2 \cdot \frac{2}{\pi} \ln 2 + N^2 \cdot \frac{1}{\tau} + Q^2 \cdot \frac{3}{\tau^2}. \quad (2)$$

Значения коэффициентов R , K , B , N , Q полинома характеризуют интенсивность отдельных шумовых составляющих выходного сигнала: R – коэффициент случайного наклона; K – интенсивность порождающего шума винеровской составляющей; B – коэффициент фликкер шума; N – интенсивность белошумной составляющей; Q – девиация шума квантования.

На практике исследуется корень квадратный из ВА, называемый *девиацией Аллана* (ДА). Для определения значений коэффициентов полинома $p_A(\tau)$ строится график девиации Аллана в логарифмическом масштабе, что позволяет линеаризовать полином $p_A(\tau)$. Характерные наклоны графика $\sigma_A(\tau)$ для этих характеристик приведены на рисунке 1 [10].



Рисунок 1. Типовые наклоны для девиации Аллана в логарифмических осях в зависимости от времени осреднения

В таблице 1 приведены обозначения типовых шумовых составляющих девиации Аллана и соответствующие им наклоны.

Таблица 1. Характеристики девиации Аллана

Коэффициент полинома $p_A^2(\tau)$	Q	N	B	K	R
Наклон $\sigma_A(\tau)$ -графика	-1	- 1/2	0	+1/ 2	+1

Формально, расчет вариации Аллана выполняется на интервале $0 \leq \tau \leq \frac{S}{2}$, где S – количество измерений. Поэтому, обработка данных заводских испытаний, продолжающихся несколько суток, занимает большое количество времени.

Оптимизация вычисления вариации Аллана

С целью сокращения времени вычислений вариации Аллана в работе [7] предложено использовать два набора точек времени осреднения, а именно:

1) $\tau_k = \Delta t \cdot 2^k$, где $k = \overline{0, NK}$, $NK = \lceil \log_2(S/2) \rceil$, знак $\lceil \rceil$ обозначает целую часть числа;

2) $\tau_k = \Delta t \cdot \lceil 2^{0,05k} \rceil$, где $k = \overline{0, NK}$, $NK = 20 \cdot \lceil \log_2(S/2) \rceil$.

Следует отметить, что второй набор точек τ , с одной стороны, предоставляет более полную информацию о поведении σ -графика по сравнению с первым, с другой – существенно сокращает время вычисления вариации Аллана по сравнению с полным перебором интервалов осреднения. Вычисление вариации Аллана в нашей работе рассчитывается по второму набору точек времени осреднения.

Для вычисления коэффициентов полинома ВА и проверки корректности расчётов используются два метода: обобщенный метод наименьших квадратов (ОМНК) и графический метод. Сущность графического метода заключается в наблюдении характерных наклонов логарифмического графика ДА, соответствующих типовым случайным процессам.

Алгоритм обобщенного метода наименьших квадратов

Согласно [8, с. 142], оценка вектора неизвестных коэффициентов x имеет вид

$$x = (H^T Q H)^{-1} H^T Q y. \quad (3)$$

Как правило, матрица Q не вырождена. Поэтому при выполнении условия наблюдаемости матрица $H^T Q H$ также является невырожденной.

В качестве матрицы Q возьмем, например, [9]:

$$Q = \text{diag} \left[\frac{M-1}{(\sigma^2(\tau_i))^2} \right] \quad (4)$$

диагональную матрицу размерности $n \times n$. Здесь M – номер группы на i -ом шаге. Преимущество ОМНК перед методом наименьших квадратов состоит в лучшей обусловленности матрицы наблюдений.

Проверка корректности вычислений вариации Аллана

Эффективность оценки коэффициентов ВА и корректность вычислений выполнены на контрольных случайных последовательностях, сгенерированных по заданным вероятностным характеристикам. В качестве примера, приведём контрольный расчёт ВА, выполненный по сгенерированной белозумной случайной последовательности. Напомним, что *белым шумом* называется случайный процесс, у которого корреляционная функция имеет вид [10, с. 97]:

$$K(\tau) = N^2 \cdot \delta(\tau), \quad (5)$$

где $\delta(\tau)$ – функция Дирака. Спектральная плотность белого шума постоянна во всем диапазоне частот

$$S(\omega) = N^2, \quad (6)$$

где величина N^2 – интенсивность белого шума. В навигации коэффициент N имеет ещё и другое название – случайное блуждание угла, отражающее физический смысл параметра.

Белозумную случайную последовательность сгенерируем для интенсивности шума $N = 10^{-6} \text{ } ^\circ/\sqrt{\text{ч}}$. Согласно [11], эта величина соответствует действительному уровню точности для волоконно-оптических гироскопов. Длина последовательности задана 1000000 значений, что обеспечит вычисление ВА с приемлемой точностью [4, 12]. В качестве шага дискретизации выбран типовой интервал опроса инерциальных датчиков $\Delta t = 0,01 \text{ с}$.

На рисунке 2 показаны графики девиации Аллана сгенерированного белозумного процесса (отмечен зеленым цветом) и его оценка по ОМНК (отмечен красным цветом).




Рисунок 2. Графики девиации Аллана белозумного процесса и его оценки по ОМНК

По рисунку 2 можно заметить, что на графике девиации Аллана наблюдается прямая с углом наклона $-1/2$, что соответствует белозумному процессу. Используя критерий минимизации, полученная оценка параметра $N = 9,90 \cdot 10^{-7} \text{ }^\circ/\sqrt{\text{ч}}$. Разность с эталонным значением оказывается на порядок меньше эталона, что позволяет говорить о корректности выполняемых вычислений ВА и алгоритма ОМНК. Оценка шумовой характеристики N с заданной длиной последовательности рассчитана с погрешностью приблизительно 3%, исходя из условия (7), описанного в следующем пункте настоящей работы.

Точность оценивания вариации Аллана

Из любого конечного количества данных можно сгенерировать конечное количество групп. Вариация Аллана любой шумовой составляющей оценивается с использованием целого числа групп заданного размера, которое может быть создано. Оценка точности вариации Аллана для заданного τ , с другой стороны, зависит от числа независимых групп в данных.

Согласно стандарту [12], можно оценить точность вариации Аллана. Процентная погрешность σ , в оценке ВА при использовании групп, содержащих D точек данных из массива данных в S точек, задается как:

$$\sigma = \frac{1}{\sqrt{2\left(\frac{S}{D}-1\right)}} \cdot 100\%. \quad (7)$$

Формула (7) показывает, что ошибки оценки на участках малых τ малы и наоборот, при больших τ велики при большом количестве независимых групп на этих участках.

Обработка экспериментальных данных

В таблицах 2, 3 представлены графики ДА; коэффициенты ДА, рассчитанные ОМНК; коэффициенты ДА, полученные графическим методом; коэффициенты ДА, рассчитанные ОМНК на уменьшенном диапазоне

времени осреднения ВА (ОМНК с уточнением). Расчёты выполнены по данным изделий, выпускаемых ПАО «ПНППК».

Таблица 2 – Численные значения коэффициентов ДА акселерометров

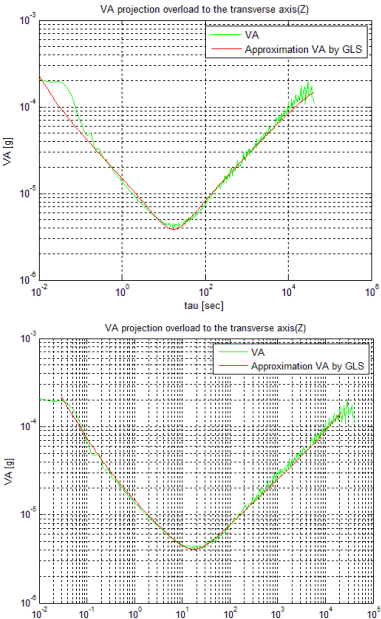
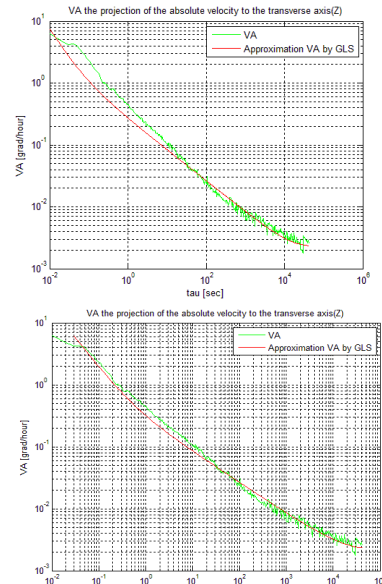
График ДА и ее аппроксимация по ОМНК	Коэффициенты ДА			
	Обозначение коэффициента ДА	Расчетное значение по ОМНК	Расчетное значение по ОМНК с уточнением	Расчетное значение графическим методом
	$Q [g \cdot c]$	$9,71 \cdot 10^{-7}$	$3,52 \cdot 10^{-6}$	$4,08 \cdot 10^{-6}$
	$N [g \cdot \sqrt{c}]$	$1,52 \cdot 10^{-5}$	$1,34 \cdot 10^{-5}$	$1,37 \cdot 10^{-5}$
	$K [g/\sqrt{c}]$	$1,51 \cdot 10^{-6}$	$1,37 \cdot 10^{-6}$	$1,35 \cdot 10^{-6}$
	$R [g/c]$	–	$5,85 \cdot 10^{-9}$	–

Таблица 3 – Значения коэффициентов ДА
ВОЛОКОННО-ОПТИЧЕСКИХ ГИРОСКОПОВ

График ДА и ее аппроксимация ОМНК	Коэффициенты ДА			
	Обозначение коэффициента ДА	Расчетное значение по ОМНК	Расчетное значение по ОМНК с уточнением	Расчетное значение графическим методом
	Q [°/ч·с]	$3,99 \cdot 10^{-2}$	$1,03 \cdot 10^{-1}$	$1,38 \cdot 10^{-1}$
	N [°/ч·√с]	$2,64 \cdot 10^{-1}$	$2,66 \cdot 10^{-1}$	$2,60 \cdot 10^{-1}$
	K [°/ч/√с]	$1,43 \cdot 10^{-5}$	–	–
	R [°/ч/с]	–	$4,38 \cdot 10^{-8}$	–

По таблицам 2,3 можно отметить:

- Для уточнения параметров, описывающих случайные составляющие погрешностей, предложено рассчитать коэффициенты ВА с помощью ОМНК на уменьшенном диапазоне времени осреднения;
- Значения коэффициентов, полученные графическим методом и ОМНК на уменьшенном диапазоне времени осреднения, практически совпадают, что подтверждает адекватность вычисления характеристик погрешностей инерциальных датчиков;
- На графиках ДА наклоны, соответствующие параметрам K (винеровский процесс), R (случайный наклон) не наблюдаются, однако ОМНК их значения получены отличными от нуля, что некорректно. Поэтому предлагается внести в методику расчёта ВА процедуру подтверждения присутствия составляющих погрешностей инерциальных датчиков K , R (а также и B): необходимо на графике ДА наблюдать наклоны $+1/2$ и $+1$, соответствующие винеровскому процессу и случайному наклону.

Заключение

Приведено описание инженерной методики оценки характеристик случайных составляющих погрешностей инерциальных измерителей методом ВА. Для получения их количественных оценок выполнена

аппроксимация логарифмического графиков ДА с помощью ОМНК. Проведено сравнение полученных оценок с результатами, получаемыми графическим методом. Для изделий, выпускаемых ПАО «ПНППК» предложено введение паспортизации их значений. Предполагается, что использование паспортизованных характеристик случайных составляющих погрешностей инерциальных датчиков в алгоритмах БИНС будет способствовать повышению точности БИНС.

Библиографический список

1. Пугачев В.С. Теория вероятностей и математическая статистика. М.: ФИЗМАТЛИТ, 2002. 496 с.
2. Бендат Дж., Пирсол А. Применение корреляционного и спектрального анализа. М.: МИР, 1983. 312 с.
3. Allan D.W. Statistic of Atomic Frequency Standard/Proc. Of the IEEE, vol. 54, № 26 1966, pp. 207-222.
4. Allan D.W. Historical, Strengths, and Weakness of Allan Variances And Their General Applications. // Methods for Navigation Sensor Performance Determination. SPb. CSCI Electropribor, 2015, pp. 507-524.
5. Stepanov O.A., Chelpanov I.B., Motorin A.V. Accuracy of Sensor Bias and its Relationship with Allan Variance. // Methods for Navigation Sensor Performance Determination. SPb. CSCI Electropribor, 2015, pp. 551-556.
6. Кучерков С.Г., Лычев Д.И., Скалон А.И., Чертков Л.А. Использование вариации Аллана при исследовании характеристик микромеханического гироскопа // Гироскопия и навигация. 2003. №2 (41). С.98-104.
7. Кутовой Д.А., Маслова О.И., Перепелкина С.Ю., Федотов А.А. К вопросу оценки шумовых составляющих измерительного тракта по методу вариации Аллана // Гироскопия и навигация. 2015. № 2 (89). С. 30-39.
8. Степанов О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. Ч. 1. Введение в теорию оценивания / Изд. 3-е, исправленное и дополненное. СПб.: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор», 2017. 509 с.
9. Степанов О.А., Моторин А.В. Сравнение методов идентификации моделей ошибок датчиков, основанных на вариациях Аллана и алгоритмах нелинейной фильтрации // XXI Санкт-Петербургская международная конференция по интегрированным навигационным системам. Сборник материалов. СПб.: АО «Конферн «ЦНИИ «Электроприбор», 2014. С. 98-103.
10. Степанов О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. Ч. 2. Введение в теорию фильтрации / Изд. 3-е, исправленное и дополненное. СПб.: ГНЦ РФ АО «Концерн «ЦНИИ «Электроприбор», 2017. 428 с.
11. Кробка Н.И. О топологии графиков вариации Аллана и типовых заблуждениях в интерпретации структуры шумов гироскопов // Материалы XXII Санкт-Петербургской международной конференции

по интегрированным навигационным системам. Круглый стол «Методы определения характеристик погрешностей навигационных датчиков». СПб.: ЦНИИ «Электроприбор». 2015. С. 457-484.

12. IEEE Std 952-1997 (R2008). Specification format guide and test procedure for single-axis interferometric fiber optic gyros: [http://emits.sso.esa.int/emits-doc/ASTRIUMLIM/GAIA_Gyro_Unit/IEEE_Std_952-1997_\(R2003\).pdf](http://emits.sso.esa.int/emits-doc/ASTRIUMLIM/GAIA_Gyro_Unit/IEEE_Std_952-1997_(R2003).pdf) (дата обращения 11.09.2020).

DEFINITION OF ERRORS RANDOM COMPONENT PARAMETERS OF STRAPDOWN INERTIAL NAVIGATION SYSTEM INERTIAL SENSOR BY THE D. ALLAN METHOD

Maria P. Zlygosteva, Larisa F. Akhtyamova, Andrey P. Kolevatov

Perm Scientific-Industrial Instrument Making Company, 106, 25th of October Str.,
Perm, 614990, Russia, m_zlyg@mail.ru

We present an engineering practice of application of D. Allan variance for definition of random components of inertial sensor errors (fiber optic gyroscopes and pendulum accelerometers) being a part of strapdown inertial navigation systems (SINS) produced by a PJSC «Perm Scientific-Industrial Instrument Making Company». This practice suggests processing of large volume data obtained during hours test of the SINS. It is suggested to use two sets of averaging time points to reduce the calculation period of D. Allan variance. To confirm accuracy of D. Allan variance computation the calculations were made with model data generated by specified probabilistic characteristics. It is shown that accuracy of estimation of D. Allan variance depends on the number of independent data groups. The results of experimental data processing obtained during hours test of various SINS are presented. To receive estimations of random errors characteristics of inertial sensors approximation is made by generalized least squares method. Obtained coefficients of D. Allan variance are used as accuracy characteristics of inertial sensors and are applied to SINS algorithms to improve navigation systems output parameters.

Key words: D. Allan variance, estimation, generalized least squares method, navigation system, accuracy.

КРЕАТИВНЫЙ СИМБИОЗ ЧЕЛОВЕКА И ИНТЕЛЛЕКТУАЛЬНОГО ИНСТРУМЕНТА

Козлов Михаил Венедиктович

Институт интеграции и профессиональной адаптации, Израиль, г. Нетания,
19mike19k@gmail.com

Анализируется возможность развития искусственного интеллекта, которая позволит создать ему новую цивилизацию, превосходящую по возможностям человеческую и предполагается, что на основе развивающихся технологий будет сформирован новый социально – экономический уклад, характеризующийся переходом от общества массового потребления товаров к обществу потребителей индивидуальной субъектно-ориентированной продукции и созданием основы для образования общества Творцов, в котором искусственный интеллект будет гармонично использоваться в качестве эффективного инструментального помощника человека. При этом эволюция человеко-инструментального взаимодействия позволит создать субъектно-ориентированный симбиоз человека и его интеллектуального помощника (alter ego) на основе искусственного интеллекта. Alter ego будет обеспечивать внешнюю связь с окружающей средой, при этом защищая индивидуальность своего хозяина. Симбиоз мозга и интеллектуального дополнения alter ego приведет к эволюции человеческого вида, составляющего децентрализованную структуру Всеобщего разума.

Ключевые слова: искусственный интеллект; человеко-инструментальное взаимодействие; неокортекс; лимбическая система; нейроинтерфейс; эпифиз.

Создание систем искусственного интеллекта (ИИ) для решения конкретных задач становится реальностью нашего времени. Такие системы зачастую превосходят возможности человека. Однако, попытки создания систем ИИ общего назначения (ИИОН) сталкиваются с непреодолимыми трудностями при работе в условиях недостаточной определенности окружающей среды. В таких условиях человек достаточно эффективно принимает робастные и адекватные ситуации решения. Поэтому проявляется повышенный интерес к анализу работы мозга и его эмуляции для создания ИИОН [1, 2, 3]. В первую очередь разработчики ИИ обратили внимание на работу неокортекса, рассматривая мозг как «широкий набор вычислительных первообразных - элементарных блоков обработки, похожих на набор основных инструкций в микропроцессоре» [4].

Для моделирования работы мозга широко используются глубинные нейронные сети (ГНС). Для повышения эффективности ГНС создают многослойные нейронные сети и уже имеются нейросети с девятью слоями,

60 миллионами параметров и 650 000 узлами [5]. ГНС хорошо справляются с задачами с четкой классификацией, при условии достаточности необходимых данных, но зависят от отклонений априорных предположений, что зачастую может привести к грубейшим ошибкам [5].

Сочетание работы ГНС с другими методами такими, как игра с самим собой, дает возможность увеличить количество данных для проведения обучающих тренировок. Однако, такие системы ИИ эффективно работают в условиях, позволяющих идеально симулировать мир, и не столь полезны в сложных реальных условиях [6]. Можно говорить, что использование ГНС, в некоторой степени, соответствует шаблонному мышлению, подводящему и человека, который на основе своего опыта априорно настраивает себя на возможные варианты при решении задачи.

Моделирование работы неокортекса для создания ИИОН, похоже, недостаточно. Мышление человека во многом иррационально, и это дает человеческому сообществу явное преимущество перед ИИ в решении задач нечетко поставленными условиями и при недостаточной информации.

В социуме людей формируется коллективный разум. Работа такого разума построена на основе децентрализованной системы, состоящей из мышления и действий отдельных индивидуумов. Достоинством такого коллективного разума можно считать процедуру поиска решений. Он использует генетический алгоритм, позволяющий в условиях неопределенности со многими экстремумами находить оптимальное решение. Такая система работает методом проб и оценок. Пробы могут осуществляться параллельно в распределенном пространстве множества думающих индивидуумов. И удача найти оптимальное решение достается индивидууму во многом случайно при неудаче множества других. Сама же оценка результата поиска закрепляется в коллективном сознании.

Применительно к коллективному разуму в social neuroscience существует представление, что в социальной группе решение совместных задач распределено между нейронными системами нескольких людей. В результате взаимодействия нескольких нервных систем модель поведения будет распределенной и описать такое взаимодействие очень сложно [7]. И для повышения уровня кооперации в обществе необходим большой горизонт взаимодействия, который, в частности, будет способствовать формированию коллективной мечты, то есть подчеркивается важная роль иррационального.

При анализе интеллектуальных возможностей человека следует обратить внимание на такие составляющие мозга, как лимбическая система, мозжечок и стриатум (полосатое тело). Работа лимбической системы, полосатого тела, мозжечка и неокортекса неразрывно взаимосвязаны. И если говорить о том, «кто в доме хозяин», рационально функционирующий неокортекс или лимбическая система и древний мозг то, по-видимому, можно отметить доминирующую, во многом иррациональную роль последних. Их работа обуславливает эмоционально-гормональную активность человека, определяет его индивидуальные особенности, имплицитно управляет его основными действиями в автоматическом режиме. Принимая информацию о

состоянии всего тела и от неокортекса эксплицитную информацию, реагирует на нее и участвует в принятии решений. Поддерживая гомеостаз, обеспечивает приспособление организма к условиям внешней среды. Участвует в формировании памяти, задает временные интервалы, способствует двигательной функции, обучению и социальному поведению. И, задавая уникальный нейрхимический профиль у людей, определяет характерные черты личности.

Таким образом, немного утрируя, мощную надстройку - неокортекс можно рассматривать как естественный интеллектуальный инструмент человеческого мозга. Ранее он мог дополняться знаниями, хранящимися в книгах, а сейчас все успешнее внешними, более интеллектуальными информационными системами.

Анализируя ситуацию, можно задать вопросы. Сможет ли ИИ погубить человечество? По-видимому, сможет. Разрушать дело нехитрое и человечество в прошлом пережило немало катаклизмов. И в этом экзистенциальный вызов ИИ человечеству. Следующий вопрос. Сможет ли ИИ, освоив рациональность иррационального поведения человека, решать сейчас ему не посильные задачи? Даст ли это ожидаемый эффект или следует использовать ИИ как высокоэффективный интеллектуальный инструмент каждого индивидуума?

Последнее, похоже, более реально в осуществлении, но для этого должны быть определенные социально-экономические предпосылки. Роботизация, использование новейших технологий способствуют резко растущему экономическому неравенству. В тоже время это позволяет создавать ресурсы для удовлетворения базовых потребностей людей, обеспечивая условия социальных изменений. В [8] рассматривается переход к субъектно-ориентированному производству и потреблению, и, вследствие этого, формированию общества Творцов, которое будет закреплено новыми социально-экономическими отношениями. Это принципиально изменит жизнь человека, приведя ее темп к естественному, и позволит посвятить себя творчеству, которое непосредственно связано с сознательной деятельностью и требует значительно большего времени, чем выполнение рутинной работы.

Интеллектуальный инструмент можно рассматривать в первую очередь как некое дополнение неокортекса. И прямой доступ к нему, осуществляемый через нейроинтерфейс, мог бы существенно расширить функциональные возможности мозга. Ряд компаний, связанных с нейротехнологиями, занимаются разработкой нейроинтерфейсов для двусторонней связи с мозгом. По мнению Илона Маска интерфейс между человеческим мозгом и компьютером жизненно необходим для противодействия наступающей сингулярности.

В [8] была рассмотрена возможность создания нейроинтерфейса в виде индивидуального помощника (alter ego), наделенного ИИ. Возможным местом размещения в мозгу alter ego может быть шишковидное тело (эпифиз), которое эволюционно связано с теменным глазом. Со встроенного в эпифиз alter ego через близко расположенный таламус, являющийся узлом

связи коры головного мозга со всеми органами чувств, возможно, удастся наладить двухстороннюю связь с неокортексом. Alter ego будет иметь возможность связи, как с мозгом, так и с внешним миром, и даже непосредственной связи «мозг-мозг».

Препятствием реализации нейроинтерфейса через эпифиз может быть то, что он является генетическим рудиментом, и с момента рождения человека его функционирование угасает [9]. Как выход из этой ситуации может быть встраивание alter ego в мозг человека при его рождении. Учитывая пластичность мозга, возможно, будет естественная адаптация такого симбиоза к окружающему миру. И может появиться новая традиция. Через некоторое время, после рождения ребенка, встраивать ему в мозг нейроинтерфейс - alter ego для возможности его скорейшей адаптации к окружающему миру. Возможно, в дальнейшем генная инженерия позволит такой alter ego сделать естественной частью мозга.

При этом, возможно, будет естественная адаптация такого симбиоза к окружающему миру. Иначе, при организации нейроинтерфейса во взрослом возрасте могут возникнуть отклонения в сознании, приводящие к раздвоению личности.

Наличие alter ego, расширяя возможности человека могут повлиять на такие функции мозга как кратковременная память, расширяя число одновременно обрабатываемых чанков (патернов), изменят матрицу эмоций и возможно повлияют на длительность сна и дефолтное состояние мозга.

В таком обществе развитие индивидуумов будет происходить согласно отработанного эволюцией механизма генетического развития, в котором присутствует некое внутривидовое ограничение. Такое ограничение математически можно представить в виде допустимого отклонения ΔR , определяемого в зависимости от выбранной метрики, выражением

$$\Delta R \leq \left| \sum_{i=1}^N \{w_{ij}(q_i - q_{mj})\}^p \right|^{1/p}, \quad (1)$$

где q_i – i -ый параметр, характеризующий рассматриваемый вид, q_{mj} – оценка среднего дискретного статистического распределения параметров по выборке субъектов данного вида на j -ом шаге смены субъектов вида, N – число параметров, w_{ij} – оценка веса параметра, p – показатель, характеризующий вид метрики, выбор которой влияет на допустимые соотношения отклонений параметров.

Оценку параметров q_i можно производить на основе лингвистических переменных с использованием 9-ти бальной шкалы Саати, а в качестве q_{mj} брать робастную оценку по репрезентативной выборке субъектов данного вида, в простейшем случае медианную.

При наличии ограничения отклонения совокупности параметров индивидуума ΔR , имеется возможность формирования его отдельных параметров q_i в достаточно широком диапазоне путем проб и оценок. Таким

образом, возможно виду избежать сингулярности и, так как величина q_{mj} не постоянна во времени и с каждой j итерацией меняется, то не ограничивается эволюционное развитие. Таким образом, будет сохраняться эволюционная тенденция в развитии человечества.

Формируемый коллективный разум должен быть децентрализованным и может функционировать по принципу технологии блокчейн. Так что на него никто не сможет оказывать доминирующего влияния. Он присутствует всюду и ни откуда конкретно не управляется. В такой децентрализованной системе коллективного разума апперцепционные системы alter ego с одной стороны будут поддерживать индивидуальность, а с другой стороны они будут и адаптивными исходя из условий окружающей среды и внутреннего состояния индивидуума.

За счет того, что отдельными индивидуумами все время будет генерироваться новая информация и будет происходить ее обмен по цепям обратной связи через апперцепционные системы нейроинтерфейсов, будет поддерживаться коллективный разум с эмерджентными свойствами.

Рассмотренный симбиоз мозга и его интеллектуального дополнения alter ego приведет в эволюции человека к виду, который можно назвать Homo intelligentes - человек интеллектуальный.

Таким образом, человеку уготована роль Творца, действующего зачастую на интуитивном иррациональном уровне, а ИИ его эффективного рационального последователя и помощника.

Библиографический список

1. Somers J. Is AI Riding a One-Trick Pony? MIT Technology Review. September 29, 2017.
2. Kozlov M. Computer-Brain Model Memory and Decision-Making. Functional Neurology, Rehabilitation, and Ergonomics. Vol.7, No. 3 (2019) – Pp.5-13.
3. Lake, B. M., Ullman, T. D., Tenenbaum, J. B., Gershman, S. J. Building Machines That Learn and Think Like People. Behavioral and Brain Sciences, 2017 – Pp.1-72.
4. Marcus, G., Marblestone, A., & Dean, T. The atoms of neural computation. Science. 2014 Oct 31; 346(6209) – Pp. 551-552.
5. Marcus G. Deep Learning: A Critical Appraisal. 2 Jan 2018. <https://arxiv.org/ftp/arxiv/papers/1801/1801.00631.pdf>
6. Почему у самообучающегося искусственного интеллекта есть проблемы с реальным миром. GeekTimes. 14.03.2018. <https://www.quantamagazine.org/why-self-taught-artificial-intelligence-has-trouble-with-the-real-world-20180221/>
7. Интервью с В.А. Ключаревым о будущем психологии. Институт психологии Российской академии наук. Социальная и экономическая психология. 2017. Том 2. № 4 (8). С. 196-223.
8. Козлов М. Заманчивые профили будущего. LAP LAMBERT Academic Publishing. 2018.

9. Хавинсон В. Х., Голубев А. Г. Старение эпифиза. Успехи геронтологии 3 (9). 2002 – С. 256-259.

CREATIVE SYMBIOSIS OF HUMAN AND INTELLECTUAL TOOL

Kozlov Michail V.

Institute of integration and professional adaptation, Netanya, Israel,
19mike19k@gmail.com

The possibility of such a development of artificial intelligence is analyzed, which will allow it to create a new civilization, superior in capabilities to a human one and it is assumed that on the basis of developing technologies a new socio-economic structure will be formed, characterized by the transition from a society of mass consumption of goods to a society of consumers of individual subject-oriented products and creating on this basis for the formation of a society of Creators, in which artificial intelligence will be harmoniously used as an effective instrumental assistant for humans. At the same time, the evolution of human-instrumental interaction will make it possible to create a subject-oriented symbiosis of a person and his intellectual assistant (alter ego) based on artificial intelligence. The alter ego will provide an external connection with the environment, while protecting the individuality of its owner. The symbiosis of the brain and the intellectual complement of the alter ego will lead to the evolution of the human species constituting the decentralized structure of the Universal Mind.

Key words: artificial Intelligence; human-instrumental interaction; neocortex; limbic system; neurointerface; pineal gland.

УДК 004.89

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ И МАШИННОЕ ОБУЧЕНИЕ В АНАЛИЗЕ ДАННЫХ МИКРОВОЛНОВОЙ РАДИОТЕРМОМЕТРИИ³

Лосев Александр Георгиевич, Попов Илларион Евгеньевич

Волгоградский государственный университет, 400062, Россия, г. Волгоград,
просп. Университетский, 100, alexander.losev@volsu.ru,
popov.larion@yandex.ru

Аннотация. Настоящая работа выполнена в рамках направления, основной целью которого является разработка фундаментальных основ ранней дифференциальной диагностики рака молочной железы на основе моделирования пространственно-временного распределения температур с помощью метода микроволновой радиотермометрии и интеллектуального

© Лосев А.Г., Попов И.Е., 2020

³ Публикация подготовлена при финансовой поддержке РФФИ (грант № 19-01-00358).

анализа получаемых данных. Рассматриваются вопросы применения методов машинного обучения в анализе данных микроволновой радиотермометрии. Также обсуждаются проблемы построения компьютерных моделей температурных полей молочных желез пациенток различных диагностических классов. С помощью компьютерного эксперимента, на базе использования набора алгоритмов машинного обучения (логистическая регрессия, наивный байесовский классификатор, метод опорных векторов, дерево решений, градиентный бустинг, К-ближайших соседей и другие), доказана адекватность набора компьютерных моделей температурных полей молочных желез, построенных в работах М.В. Полякова и А.В. Хоперскова.

Ключевые слова: машинное обучение, микроволновая радиотермометрия, рак молочной железы.

В настоящее время при разработке новых способов медицинской диагностики стали активно применяться методы математического моделирования и машинного обучения. В том числе данный подход обеспечивает возможность создания эффективных методик функциональной диагностики, основанных на измерении, описании и интерпретации параметров физических полей организма человека. Однако развитие инструментальной базы медицины привело к тому, что проблемы в постановке диагностического решения в большинстве случаев возникают не из-за дефицита информации, а из-за недостаточной эффективности методов ее обработки. Решение указанных проблем обеспечивает создание систем интерпретации и анализа медицинских данных [1]. Подобные системы, используя методы и алгоритмы машинного обучения, должны помогать специалистам в задачах постановки диагнозов, прогнозирования развития заболеваний [2].

Одновременно отметим одну из наиболее сложных и актуальных задач медицины, которой является проблема ранней диагностики заболеваний молочных желез. Рак молочной железы является наиболее распространенным онкологическим заболеванием среди женщин. Вполне очевидным представляется решение задачи повышения выживаемости с помощью раннего выявления данного заболевания. Одним из наиболее перспективных для повышения эффективности ранней диагностики рака молочных желез видится метод микроволновой радиотермометрии [3].

Данное исследование выполнено в рамках направления, основной целью которого является разработка фундаментальных основ ранней дифференциальной диагностики заболеваний молочных желез на основе моделирования пространственно-временного распределения температур с помощью метода микроволновой радиотермометрии и интеллектуального анализа получаемых данных.

Известно, что ткани человека, как и любого нагретого тела, излучают электромагнитные колебания в широком диапазоне частот. При этом спектр излучения и интенсивность собственного электромагнитного излучения тканей в микроволновом диапазоне определяется как распределением

температуры, так поглощением и переизлучением в физически неоднородных тканях. Ситуация осложняется тем, что при температуре человеческого тела максимум излучения приходится на ближний инфракрасный диапазон, спектр которого формируется на поверхности биоткани. А информация о распределении внутренней температуры на глубине несколько сантиметров обусловлена более длинноволновым излучением, на порядки более слабым. Таким образом, измеряя это излучение, мы получаем крайне важную информацию о состоянии внутренних тканей и кожных покровов. Именно в этом и состоит основная идея метода микроволновой радиотермометрии (РТМ), основанного на измерении собственного излучения тканей в микроволновом и инфракрасном (ИК) диапазонах длин волн.

В течение последних двух десятилетий данный метод получил распространение в различных областях медицины [4]. При этом анализ его практического применения обозначил ряд задач, требующих своего решения. Прежде всего, возникла необходимость в разработке адекватных компьютерных физико-математических моделей исследования пространственной и временной динамики температурных полей в биотканях молочной железы. В последние годы, при проведении теоретических исследований, был создан ряд математических моделей, описывающих распределение температуры в органах человека [4-7]. В том числе в работах [5-7] при моделировании стали учитываться основные макроскопические факторы, определяющие тепловую динамику. Вместо традиционно используемых моделей с однородными параметрами в многослойном приближении (обычно ограничиваются четырьмя типами тканей – кожа, мышцы, молочная железа, опухоли), при моделировании использовалась близкая к реалистичной геометрическая структура биотканей с гетерогенными характеристиками. В разработанных моделях также учитывались нитевидные соединительные ткани, дольки МЖ, сосок, выводные протоки, жировая ткань. Отметим, большое количество входных физических параметров серьезно усложняет процесс моделирования, но, одновременно, значительно повышает адекватность модели. В реальных условиях разброс значений этих параметров лежит в очень широких пределах. Также в исследовании на основе глубокого анализа медицинских данных и с помощью алгоритмов машинного обучения был предложен алгоритм валидации имитационной модели [6].

С другой стороны, в последние годы активно изучались возможности использования алгоритмов машинного обучения в постановке и обосновании диагностического решения на основе данных микроволновой радиотермометрии [2,4,8,9]. Достаточно быстро было установлено, что попытка постановки диагноза методами искусственного интеллекта на основе исключительно температурных данных не обеспечивает требуемую чувствительность и специфичность. Были предложены различные варианты термометрических признаков пространств [2, 8]. В основе их построения лежит набор описательных гипотез о поведении температурных полей

пациенток разных диагностических классов. В частности, у пациенток с патологией отмечается наличие повышенной величины термоасимметрии между одноименными точками молочных желез; повышенный разброс температур между отдельными точками в пораженной молочной железе; повышенная температура соска в пораженной молочной железе по сравнению со средней температурой молочной железы с учетом возрастных изменений температуры; соотношение кожной и глубинной температур и некоторые другие. При исследовании были обнаружены и описаны количественные характеристики указанных выше термометрических факторов. На основе признаков пространств указанного типа был построен ряд алгоритмов классификации. В частности, наиболее эффективные алгоритмы классификации, построенный на основе логистической регрессии, показали чувствительность и специфичность в районе 0.65 – 0.7 [8]. Как и ожидалось, достаточно высокую эффективность дает применение искусственных нейронных сетей. Однако и здесь специфическая предобработка входного сигнала на основе соответствующих признаков пространств [8] позволила существенно увеличить точность. А именно, комбинированное использование в первом слое моделирующих функций и результатов анамнеза, предложенное в [9], позволило увеличить эффективность классификатора более чем на 10 процентов по сравнению с использованием во входном слое исключительно значений температур [2]. Чувствительность и специфичность в модели искусственной нейронной сети, предложенной в [9], достигли значений 0.8 – 0.85.

В данной работе предлагается модель модернизации существующей методики диагностики рака молочной железы по данным микроволновой радиотермометрии. Предполагается, что основу метода составит гибридная технология, основанная на математическом моделировании тепловых полей и интеллектуальном анализе термометрических данных. На первом этапе планируется проведение измерений температур в ИК и РТМ-диапазонах на основе существующей стандартной методики. Далее с помощью методов Data Mining определяется предполагаемый диагноз и возможное месторасположение злокачественных новообразований. На следующем этапе, используя соответствующие компьютерные модели, планируется измерение внутренних и поверхностных температур по модифицированной методике. Новые термометрические данные позволят существенно уточнить прогноз по поведению температурных полей внутри молочных желез. Однако подобный подход предъявляет крайне высокие требования к качеству набора температурных данных, полученных с помощью компьютерного моделирования.

Проверка адекватности модели, в частности ее валидация, осуществлялась следующим образом. Рассматривались две базы термометрических данных: оригинальная база, т.е. полученная в онкологических центрах на основе обследования пациенток различных классов, и база модельных данных, полученных с помощью компьютерного моделирования. Первая включает в себя термометрические данные

о 109 здоровых правых молочных желез (МЖ) и 27 больных раком правых МЖ. Вторая включает в себя термометрические данные о 159 здоровых и 160 больных правых МЖ. Выбор именно правых МЖ связан с тем обстоятельством, что существующий набор компьютерных моделей посчитан именно для правых МЖ. Далее, на основании этих баз, были созданы четыре группы обучающих и тестовых выборок. В обучающую выборку группы А было включено половина данных здоровых и больных из оригинальной базы, а в тестовую все данные из базы модельных данных. В обучающую выборку группы В включалось 0.9 данных из базы модельных данных, а тестовую – все данные оригинальной базы. В обучающую выборку группы С было включено половина данных здоровых и больных из оригинальной базы, все остальные были включены в тестовую выборка. В обучающую выборку группы D было включено половина данных здоровых и больных из оригинальной базы и все модельные данные, а в тестовую – оставшая часть оригинальной базы. Классификация проводилась с помощью следующих алгоритмов: К-ближайших соседей, наивный байесовский классификатор, дерево решений, лес решений, логистическая регрессия, градиентный бустинг, метод опорных векторов. В качестве меры эффективности использовалось среднее геометрическое между чувствительностью и специфичностью. Были получены следующие результаты.

В группе А лучшие результаты были получены с помощью логистической регрессии и наивного байесовского классификатора. Мера их эффективности составила, соответственно, 0.54 и 0.52. В группе В лучшие результаты были получены с помощью наивного байесовского классификатора (мера эффективности – 0.73) и логистической регрессии (мера эффективности – 0.63). В группе С лучшие результаты были получены с помощью логистической регрессии, где мера эффективности составила 0.79. Достаточно хорошие результаты показали метод опорных векторов (мера эффективности – 0.71), а также наивный байесовский классификатор и дерево решений (мера эффективности – 0.68). В группе D лучшие результаты были получены с помощью алгоритмов: градиентный бустинг (мера эффективности – 0.81), метод опорных векторов (мера эффективности – 0.8), наивный байесовский классификатор (мера эффективности – 0.8) и логистическая регрессия (мера эффективности – 0.8). Можно предположить, что мера эффективности в первых группах снизилась по сравнению с результатами работ [8] и [9] вследствие уменьшения признакового пространства. А именно, не использовались показатели термоасимметрии, одни из наиболее эффективных элементов признакового пространства. Последнее ставит задачу разработки компьютерных моделей парных органов в совокупности, а не в отдельности каждого органа. Также не использовались признаки, базирующиеся на температурах в опорных точках и аксилярной области. Кроме того, если сравнивать с результатами, полученными на основе нейронных сетей, не использовалось большинство данных анамнеза (возраст, индекс веса и т.п.). Отдельно отметим, что попытка использовать значения температур левых МЖ, путем соответствующего симметричного

отображения, в группе А несколько улучшила меру эффективности (в среднем на 0.02), а в группах В, С и D несколько ухудшила ее (в группе В – в среднем на 0.05, в группе С – в среднем на 0.02, в группе D – в среднем на 0.08). Последнее показывает необходимость уточнения гипотезы о симметричном поведении температурных полей парных органов.

В целом, полученные результаты показывают достаточно высокую степень адекватности полученных в [5 – 7] компьютерных моделей температурных полей молочных желез и возможность их использования при разработке гибридной методики диагностики рака молочной железы на основе данных микроволновой радиотермометрии.

Библиографический список

1. Yasnitsky L.N., Dumler A.A., Poleshuk A.N., Bogdanov C.V., Cherepanov F.M. Artificial Neural Networks for Obtaining New Medical Knowledge: Diagnostics and Prediction of Cardiovascular Disease Progression // *Biology and Medicine (Aligarh)*. 2015. V. 7. Is. 2. P. BM-095-15.
2. Levshinskii V., Galazis C., Ovchinnikov L., Vesnin S., Losev A., Goryanin I. Application of Data Mining and Machine Learning in Microwave Radiometry (MWR) // *Communications in Computer and Information Science*. 2020. V. 1211 CCIS. p. 265 – 288.
3. Vesnin S., Turnbull A.K., Dixon J.M., Goryanin I. Modern Microwave Thermometry for Breast Cancer // *Journal of Molecular Imaging & Dynamics*. 2017. V. 7, Is. 2. DOI: 10.4172/2155-9937.1000136.
4. Лосев А. Г., Хоперсков А. В., Астахов А. С., Сулейманова Х. М. Проблемы измерения и моделирования тепловых и радиационных полей в биотканях: анализ данных микроволновой радиотермометрии // *Вестник Волгоградского государственного университета. Серия 1: Математика. Физика*. 2015. № 6. с. 31-71.
5. Поляков М.В., Хоперсков А.В. Вычислительные эксперименты для исследования радиационных и тепловых полей в биоткани // *Инженерный вестник Дона*. 2017. Т. 45, №2. С. 81.
6. Levshinskii V., Polyakov M., Losev A., Khoperskov A.V. Verification and Validation of Computer Models for Diagnosing Breast Cancer Based on Machine Learning for Medical Data Analysis // *Communications in Computer and Information Science*. 2019. V. 1084. p. 447 – 460.
7. Polyakov M., Levshinskii V., Khoperskov A. Modeling of brightness temperature in biological tissue // *Journal of Physics: Conference Series*. 2019. V. 1368. p. 042057.
8. Лосев А. Г., Левшинский В. В. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы // *Математическая физика и компьютерное моделирование*. 2017. № 5 (342). С. 16-22.
9. Лосев А.Г., Медведев Д.А. Применение нейронных сетей в диагностике рака молочной железы по данным микроволновой радиотермометрии // *Современная наука и инновации*. 2019. Т. 4. № 28. С. 22-28.

MATHEMATICAL MODELING AND MACHINE LEARNING IN ANALYSIS OF MICROWAVE RADIOTHERMOMETRY DATA

Losev Alexander G., Popov Illarion E.

Volgograd State University, 100, Prospect Universitetsky, Volgograd, 400062,
Russia, alexander.losev@volsu.ru, popov.larion@yandex.ru

This work was done with the aim of developing the fundamental foundations of early differential diagnosis of breast cancer based on modeling the space-time temperature distribution using the microwave radiothermometry method and intelligent analysis of the obtained data. The article deals with the application of machine learning methods in the analysis of microwave radiothermometry data. The problems of constructing computer models of the temperature fields of the mammary glands of patients of various diagnostic classes are also discussed. With the help of a computer experiment, based on the use of a set of machine learning algorithms (logistic regression, naive Bayesian classifier, support vector machine, decision tree, gradient boosting, K-nearest neighbors, etc.), the adequacy of the set of computer models of the temperature fields of the mammary glands, modelled in works of M.V. Polyakov and A.V. Khoperskov.

Key words: machine learning, microwave radiometry, breast cancer.

УДК 531.

УРАВНЕНИЯ ДИНАМИКИ МАНИПУЛЯТОРОВ С ШЕСТЬЮ СТЕПЕНЯМИ СВОБОДЫ

Телегин Александр Иванович, Пудовкина Светлана Геннадьевна

Филиал федерального государственного автономного образовательного учреждения высшего образования «Южно-Уральский государственный университет (национальный исследовательский университет)» в г. Миассе 456318, Россия, Челябинская область, г. Миасс, пр. Октября, д. 16,
pudovkinasg@susu.ru

Решается проблема громоздкости уравнений динамики (УД) систем тел со многими степенями свободы. Предложен новый формализм вывода УД манипуляционных систем (МС) промышленных роботов, состоящих из поступательных (ПКП) и вращательных (ВКП) кинематических пар (КП). Приведены пять примеров вывода УД МС с шестью телами, работающих в декартовой, цилиндрической, сферической и ангулярной системах координат (СК). В полученных УД явно выражены геометрические, кинематические, статические и инерционные параметры МС. По известным классическим формализмам (Лагранжа, Аппеля, Нильсена, Ньютона-Эйлера и т.д.) практически невозможно получить аналогичные результаты из-за большого

количества сложных математических операций в их реализации и громоздкости получаемых формул. Множители при ускорениях и произведениях скоростей в записанных здесь УД являются оптимальными в смысле минимума арифметических операций (сложений и умножений), необходимых для их вычислений. Записанные аналитические виды УД занимают несколько строк в отличие от десятков страниц машинописного текста в записи УД, полученных, например, по формализму Лагранжа.

Ключевые слова: промышленные роботы, уравнения динамики, выписывание формул, повторное использование формул.

Введение

УД МС с N телами имеют следующий векторно-матричный вид

$$H(q)\ddot{q} + h(q, \dot{q}) + G(q) = Q, \quad (1)$$

где $q, \dot{q}, \ddot{q} \in R^N$ – векторы обобщенных координат, скоростей и ускорений тел, $H(q) \in R^{N \times N}$ – симметричная положительно-определенная матрица инерционных коэффициентов, $h(q, \dot{q}) \in R^N$ – вектор-столбец центробежных, Кориолисовых и гироскопических инерционных сил, $G(q)$ – вектор-столбец обобщенных сил тяжести, Q – вектор-столбец обобщенных движущих сил. Основной проблемой практического использования УД (1) является их громоздкость. Это следствие неэффективности классических формализмов вывода УД МС. В частности поэтому в научных статьях в качестве примеров демонстрируются, как правило, плоские двухзвенники [1 – 5]. До сих пор встречаются научные статьи, в которых по формализму Лагранжа на нескольких страницах выводятся УД простейших МС [6, 7], в то время как современные формализмы позволяют выписывать УД таких МС в нескольких строках [8, 9].

Цель статьи – описать эффективный формализм выписывания УД МС и привести примеры выписывания УД МС, изображенных на рис. 1 – 5.

Входные параметры МС

Здесь используются следующие параметры МС: m_{oi} – обозначение и масса тела с порядковым номером i ; δ_i – код типа КП(i), где $\delta_i = 1$, если тело m_{oi} вращается относительно предшествующего тела; $\delta_i = 0$, если тело m_{oi} движется поступательно относительно предшествующего тела; \bar{q}_i – орт оси вращения тела m_{oi} относительно тела m_{oi-1} ; \bar{p}_i – орт оси поступательного движения тела m_{oi} относительно тела m_{oi-1} ; O_i – полюс тела m_{oi} (неподвижная точка тела); $\bar{R}_k = \overline{O_{k-1}O_k}$ – межполюсный вектор КП(k); C_i – центр масс (ЦМ) тела m_{oi} ; $a_k = m_{ok}|\overline{O_{k-1}C_k}|$ – модуль статического момента тела m_{ok} относительно его полюса; $\bar{c}_k = \overline{O_{k-1}C_k}/|\overline{O_{k-1}C_k}|$ – орт, направленный из полюса O_k в ЦМ C_k ; $O_i \bar{x}_i \bar{y}_i \bar{z}_i$ – СК, жестко связанная с телом m_{oi} ; q_i – угол поворота тела m_{oi} (случай $\delta_i = 1$); $q_i = O_{oi}O_i$ – величина поступательного перемещения тела m_{oi} (случай $\delta_i = 0$), где O_{oi} – исходное положение полюса O_i , жестко связанное с телом m_{oi-1} ; I_i^x, I_i^y, I_i^z – моменты инерции тела m_{oi} относительно главных осей $O_i \bar{x}_i, O_i \bar{y}_i, O_i \bar{z}_i$ соответственно.

Полюс вращающегося тела выбирается на оси его вращения, и полюса тел максимально совмещаются. В исходном положении МС оси связанных СК (ССК) тел будем направлять параллельно соответствующим осям неподвижной СК $O\bar{x}\bar{y}\bar{z}$. В этой СК ось $O\bar{x}$ направлена горизонтально вправо, ось $O\bar{y}$ направлена вертикально вверх и ось $O\bar{z}$ направлена так, что СК $O\bar{x}\bar{y}\bar{z}$ – правая. Через m_i будем обозначать i -ю подсистему и ее массу. Например, для МС на рис.1–5 в подсистему m_3 входят тела m_{o3} , m_{o4} , m_{o5} , m_{o6} . На рисунках полюса тел отмечены точками, а ЦМ звездочками. В схемах МС на рис.1–5 тела ВКП изображены в исходном относительном положении, т.е. до начала вращательных движений тел. Поэтому орты ССК здесь не изображены (они параллельны соответствующим ортам осей $O\bar{x}$, $O\bar{y}$, $O\bar{z}$ неподвижной СК).

Выписывание матрицы Н

Элементы G_k вектора G и элементы H_{kj} матрицы инерционных коэффициентов (МИК) H в УД (1) можно выписывать по формулам (2) – (7) на рис.6, которые получены в работах [8, 10]. Здесь \bar{m}_k – статический момент подсистемы m_k относительно полюса O_k . Его выражение через орты ССК выписывается по векторной обратной рекуррентной формуле (2). Выпишем \bar{m}_k для МС на рис. 1 – 4 для $k=6,5,4,3$, т.е. для их общих подсистем. Для $k=N=6$ по формуле (2) получим $\bar{m}_6 = a_6 \bar{c}_6$. Подставим сюда $\bar{c}_6 = -\bar{y}_5$. Тогда окончательно получим $\bar{m}_6 = -a_6 \bar{y}_5$. Для $k=5$ с учетом равенства $\bar{R}_6 = 0$ по формуле (2) получим $\bar{m}_5 = a_5 \bar{c}_5 + \bar{m}_6$. Подставим сюда $\bar{c}_5 = -\bar{y}_5$ и используем обозначение $a = a_5 + a_6$. Тогда окончательно получим $\bar{m}_5 = -a \bar{y}_5$. Аналогично $\bar{R}_5 = 0$, $\bar{c}_4 = y_3$, т.е. $\bar{m}_4 = a_4 \bar{y}_3 - a \bar{y}_5$. Для $k=3$ с учетом равенств $\bar{R}_4 = -q_4 \bar{y}_3$, $\bar{c}_3 = -\bar{y}_3$ по формуле (2) получим $\bar{m}_3 = -a_3 \bar{y}_3 - m_4 q_4 \bar{y}_3 + \bar{m}_4$. После подстановки \bar{m}_4 и приведения подобных членов окончательно получим $\bar{m}_3 = m_{q4} \bar{y}_3 - a \bar{y}_5$, где $m_{q4} = a_4 - a_3 - m_4 q_4$. Таким образом, искомые выражения статических моментов вычисляются по формулам (8), где для МС на рис.1–3 $\bar{y}_3 = \bar{y}$. Статические моменты \bar{m}_2 и \bar{m}_1 для этих МС отличаются. Их выпишем по мере необходимости. Статические моменты для МС на рис.5 выписываются аналогично и имеют вид (9).

Из формулы (3) видно, что если $\bar{p}_k \perp \bar{y}$ или $\bar{q}_k \parallel \bar{y}$, то $G_k = 0$. Для МС на рис.1 $G_1 = G_2 = G_3 = 0$, так как $\bar{p}_1 = \bar{z} \perp \bar{y}$, $\bar{p}_2 = \bar{x} \perp \bar{y}$, $\bar{q}_3 = \bar{y}$. Для МС на рис.1 – 3 по формуле (3) получим $G_4 = g m_4 \bar{y} \cdot \bar{p}_4$. Следовательно, для этих МС $G_4 = -g m_4$, так как $\bar{y} \cdot \bar{p}_4 = -\bar{y} \cdot \bar{y} = -1$. Для МС на рис.4 $G_4 = -g m_4 \bar{y} \cdot \bar{y}_3 = -g m_4 c_2$. Здесь и далее используются обозначения $c_i = \cos q_i$, $s_i = \sin q_i$. Для $k=5$ по формуле (3) получим $G_5 = g \bar{y} \cdot \bar{q}_5 \times \bar{m}_5 = -a g \bar{y} \cdot \bar{z}_3 \times \bar{y}_5 = a g \bar{y} \cdot \bar{x}_5 = a g x_5^y$. Здесь и далее для направляющих косинусов орт ССК(j) в ССК(i), где $i < j$, используется обозначение $\eta_{ji}^\zeta = \bar{\eta}_j \cdot \bar{z}_i^\zeta$, где $\eta, \zeta \in \{x, y, z\}$. Выписывать η_{ji}^ζ рекомендуется по формулам (10), где $i=j, j-1, \dots, 1$. Для МС на рис. 1 – 5 $G_6 = g \bar{y} \cdot \bar{q}_6 \times \bar{m}_6 = -a g \bar{y} \cdot \bar{y}_5 \times \bar{y}_5 = 0$. Аналогично выписываются G_k для МС на рис.5. Их отличные от нуля искомые виды приведены в формулах (11).

Диагональные элементы МИК H выписываются по формуле $\hat{\delta}_k m_k + \delta_k J_k^q$, где J_k^q – момент инерции подсистемы m_k относительно оси $O\bar{q}_k$. Для

уменьшения записей здесь считается, что тела МС на рис. 1 – 5 имеют ось симметрии. Для таких МС J_k^q можно выписывать по формуле (4), где I_i^n – момент инерции тела m_{oi} относительно оси $O\bar{\eta}_i$; $\bar{\zeta}_i = \bar{x}_i$, $\bar{\eta}_i = \bar{z}_i$, $I_{xi}^z = I_i^z - I_i^x$, если тело m_{oi} симметрично оси $O\bar{x}_i$; $\bar{\zeta}_i = \bar{y}_i$, $\bar{\eta}_i = \bar{x}_i$, $I_{yi}^x = I_i^x - I_i^y$, если тело m_{oi} симметрично оси $O\bar{y}_i$; $\bar{\zeta}_i = \bar{z}_i$, $\bar{\eta}_i = \bar{y}_i$, $I_{zi}^y = I_i^y - I_i^z$, если тело m_{oi} симметрично оси $O\bar{z}_i$. Из-за ограниченного объема статьи опишем только типовые действия выписывания по формулам (4) – (7). Действуя аналогично легко выписать все выражения самостоятельно.

Для $k=N=6$ по формуле (4) получим $J_6^q = I_6^q - I_{z_6}^n (\bar{q}_6 \cdot \bar{\zeta}_6)^2$. Для МС на рис.1 – 5 тело m_{oi} симметрично оси $O\bar{y}_i$, где $i=6,5,4,3$, т.е. $\bar{\zeta}_i = \bar{y}_i$, $\bar{\eta}_i = \bar{x}_i$. Тогда с учетом равенства $\bar{q}_6 = \bar{y}_5$ получим $J_6^q = I_6^q - I_{y_6}^x (\bar{y}_5 \cdot \bar{y}_6)^2$, $\bar{y}_5 \cdot \bar{y}_6 = 1$. Следовательно, $J_6^q = I_6^x - I_{y_6}^x = I_6^y$. Для $k=5$ единственное слагаемое последней суммы в формуле (4) равно нулю, так как $\bar{R}_6 = 0$. Тогда $J_5^q = I_5^q - \sum_{i=5}^6 I_{y_i}^x (\bar{q}_5 \cdot \bar{y}_i)^2$. Для МС на рис.1 – 4 $\bar{q}_5 = \bar{z}_3$, т.е. $\bar{q}_5 \cdot \bar{y}_i = 0$. Следовательно, $J_5^q = I_5^q$. Для $k=3$ в формуле (4) работают все суммы, так как $\bar{R}_4 = -q_4 \bar{y}_3$. Соответствующие выкладки выписывания приведены в формулах (12).

МИК H симметрична. Поэтому достаточно выписать ее под диагональные элементы, т.е. в формуле (5) $j < k$. Здесь $\bar{m}_{jk} = m_k \bar{R}_{jk} + \bar{m}_k$ – статический момент подсистемы m_k относительно полюса O_j . Вектор \bar{R}_{jk} начинается в полюсе O_j и O_k – его конец. Из обозначения $R_{ij}^q = \bar{R}_i \cdot \bar{q}_j$ видно, что если $\bar{R}_i = 0$ или $\bar{R}_i \perp \bar{q}_j$, то $R_{ij}^q = 0$. Для заданных k и j в формуле (5) выписывается только один множитель, стоящий после произведений кодов КП. Для $k=6$ и $j=5$ необходимо выписать выражение при $\delta_6 \delta_5$, так как остальные слагаемые равны нулю. Учитывая, что $\bar{R}_{56} = 0$, по формуле (5) выпишем $H_{65} = I_6^q \bar{y}_5 \cdot \bar{z}_3 - I_{y_6}^x \bar{y}_5 \cdot \bar{y}_6 \bar{z}_3 \cdot \bar{y}_6 = 0$. Для $k=6$ и $j=4$ необходимо выписать выражение при $\delta_6 \delta_4$, т.е. $H_{64} = \bar{p}_4 \cdot \bar{q}_6 \times \bar{m}_6 = -a_6 \bar{p}_4 \cdot \bar{y}_5 \times \bar{y}_6 = 0$. Если $k=4$ и $j=3$, то необходимо выписать выражение при $\delta_4 \delta_3$, т.е.

$$H_{43} = \bar{p}_4 \cdot \bar{q}_3 \times \bar{m}_{34} = -\bar{y}_3 \cdot \bar{y}_3 \times \bar{m}_{34} = 0.$$

Для МС на рис.1 $H_{21} = \delta_2 \delta_1 m_2 \bar{p}_1 \cdot \bar{p}_2 = 0$, так как $\bar{p}_1 \perp \bar{p}_2$. Аналогично выписываются остальные элементы МИК H . В формулах (13) представлены соответствующие выражения выписывания. Здесь общая часть МИК H для МС на рис. 1 – 4 имеет вид (14), где $I_a = I_3^y + I_4^y + I_5^q$, $I_b = I_{y_5}^x + I_{y_6}^x$.

В предлагаемом методе выписывания УД применяется повторное использование уже выписанных формул для разных МС, если эти МС имеют совпадающие подсистемы. Например, в МИК (14) для МС на рис.1–4 повторно используются элементы, стоящие правее второго столбца и ниже второй строки. В одной МС повторно используется выписанная формула для несомого тела в процессе выписывания формулы для несущего тела, если их оси вращения параллельны. Например, если $j < k$, $\delta_j = \delta_k = 1$, $\bar{q}_j \parallel \bar{q}_k$, то J_j^q проще выписывать по формуле (6), так как в ней используется уже выписанное выражение J_k^q . Эту формулу легко получить путем тождественного преобразования формулы (4). Аналогично, если $j < k$, $\delta_j = \delta_k = 1$, $\bar{q}_j \parallel \bar{q}_k$, то

справедлива первая формула (7). Или, если $i < j < k$, $\delta_i = \delta_j = \delta_k = 1$, $\bar{q}_i \parallel \bar{q}_j$, то справедлива вторая формула (7). В формулах (5) и (7) используется диадное произведение векторов [11]. Однако при выписывании H_{kj} в вычислении этого произведения нет необходимости. Действительно, после раскрытия скобок все сводится к вычислению скалярных произведений векторов. Запись $\bar{q}_k \bar{m}_k - \bar{m}_k \bar{q}_k$ позволяет обнулить это выражение, если $\bar{m}_k \parallel \bar{q}_k$, или сократить его, если \bar{m}_k имеет составляющие, которые параллельны орту \bar{q}_k . Рассмотрим примеры повторного использования формул при выписывании недостающих элементов МИК H для МС на рис. 3. Момент инерции J_2^q выписывается по формуле (6), где $k=3, j=2$, так как $\bar{q}_2 \parallel \bar{q}_3$. Соответствующие выкладки представлены в формулах (15). Момент инерции J_1^q выписывается по формуле (6), где $k=2, j=1$, так как $\bar{q}_1 \parallel \bar{q}_2$. Соответствующие выкладки представлены в формулах (16). По второй формуле (7) выпишем H_{62} , повторно используя H_{63} . В выписывании H_{61} используется H_{62} . H_{52} вычисляется через H_{53} , а H_{51} через H_{52} , и все потому, что $\bar{q}_1 \parallel \bar{q}_2 \parallel \bar{q}_3$. Соответствующие выкладки представлены в формулах (17). По первой формуле (7) выпишем H_{32} , повторно используя J_3^q . В выписывании H_{21} повторно используется J_2^q . Соответствующие выкладки представлены в формулах (18). Аналогично выписываются элементы МИК H для МС на рис. 1 – 5. Конечные результаты приведены на рис. 7.

Вывод инерционных сил

Элементы h_k вектора h в УД (1) можно выписать по общим формулам [8, 10] аналогично выписыванию элементов МИК H . Но когда получена и оптимизирована МИК H элементы вектора h не сложно вывести по формуле (19) на рис.8. Докажем эту формулу. Действительно, если известна МИК H , то кинетическая энергия МС и ее производные вычисляются по формулам (20). Тогда, отбросив в выражении $\frac{d(\frac{\partial T}{\partial \dot{q}_k})}{dt} - \frac{\partial T}{\partial q_k}$ слагаемые с ускорениями, получим формулу (19). Очевидно, что если q_k – циклическая, то формула (19) принимает более простой вид (21), так как частные производные по q_k равны нулю.

Выведем по формулам (19), (21) элементы h для МС на рис. 1. Из матрицы H видно, что координаты q_1, q_2, q_4, q_6 – циклические. Следовательно, h_1, h_2, h_4, h_6 выводим по формуле (21). Вывод h_1, h_2 представлен в формулах (22). Прокомментируем их подробнее. Здесь для $k=1$ первое слагаемое в формуле (21) равно нулю, так как $\delta_1=0$. Первая сумма отсутствует, так как для $k=1$ ее верхний предел суммирования равен нулю. Вторая сумма содержит слагаемые только для $j=3$ и $j=5$, так как $H_{21} = H_{41} = H_{61} = 0$. Для $k=2$ первое слагаемое равно нулю, так как $\delta_2=0$. Первая сумма равна нулю, так как $H_{21} = 0$. Вторая сумма содержит слагаемые только для $j=3$ и $j=5$, так как $H_{42} = H_{62} = 0$. Для $k=4$ первое слагаемое равно нулю, так как $\delta_4=0$. Первая сумма равна нулю, так как $H_{4i} = 0$. Вторая сумма содержит слагаемые только для $j=5$, так как $H_{64} = 0$. Таким образом, $h_4 = -ac_5 \dot{q}_5 \dot{q}_5$. Для $k=6$ первое слагаемое

равно нулю, так как $I_6^y = \text{const}$. Первая сумма содержит только одно слагаемое, так как H_{63} зависит от времени. Вторая сумма отсутствует, так как нижний предел суммирования больше верхнего. Следовательно, получим $h_6 = \dot{H}_{63} \dot{q}_3 = -I_6^y s_5 \dot{q}_3 \dot{q}_5$.

Элементы h_3 и h_5 выводятся по формуле (19) и соответствующие выкладки представлены в формулах (23). Здесь для $k=3$ первое слагаемое отлично от нуля, так как $\delta_3=1$ и J_3^q зависит от t . Первая сумма содержит слагаемые для $i=1,2$, так как H_{31}, H_{32} зависят от t . Вторая сумма содержит слагаемые только для $j=6$, так как $H_{43} = H_{53} = 0$. Двойная сумма содержит слагаемые только для $j=3$ и $j=5$, так как только $H_{31}, H_{32}, H_{51}, H_{52}$ зависят от q_3 . Для $k=5$ первое слагаемое равно нулю, так как $J_5^q = \text{const}$. В первой сумме первая составляющая отлична от нуля для $i=1,2,4$, так как $H_{53} = 0$. Вторая составляющая отлична от нуля только для $i=3$, так как только J_3^q зависит от q_5 . Вторая сумма слагаемых не содержит, так как $H_{65} = 0$. Двойная сумма имеет шесть слагаемых, так как $H_{31}, H_{32}, H_{51}, H_{52}, H_{54}, H_{63}$ зависят от q_5 . Таким образом, УД МС на рис.1 имеют вид, представленный на рис.8. Действуя аналогично, легко получить УД рассматриваемых МС. Для МС с цилиндрической СК они приведены на рис.8. Выражения используемых направляющих косинусов через s_i, c_i выписаны по формулам (10).

Желающие получить аналитические виды УД всех МС с их подробным описанием можно обращаться к авторам статьи по указанному адресу.

Заключение

Здесь впервые для основных схем построения МС выписаны их УД в аналитическом виде с явно выраженными геометрическими, кинематическими, статическими и инерционными параметрами тел. Причем сократить количество математических операций в этих УД практически невозможно, т.е. они оптимальны в смысле быстрогодействия вычислений. Еще недавно такой результат был практически не достижимым. Но теоретическая механика развивается и предоставляет новые возможности исследования МС.




Рис.1. МС с декартовой СК.




Рис.3. МС с ангулярной (в горизонтали) СК.

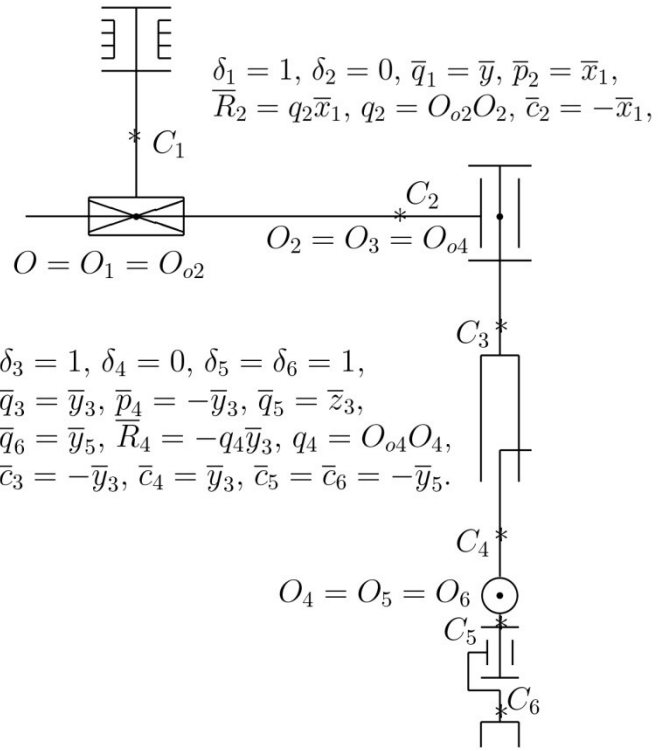


Рис.2. МС с цилиндрической СК.

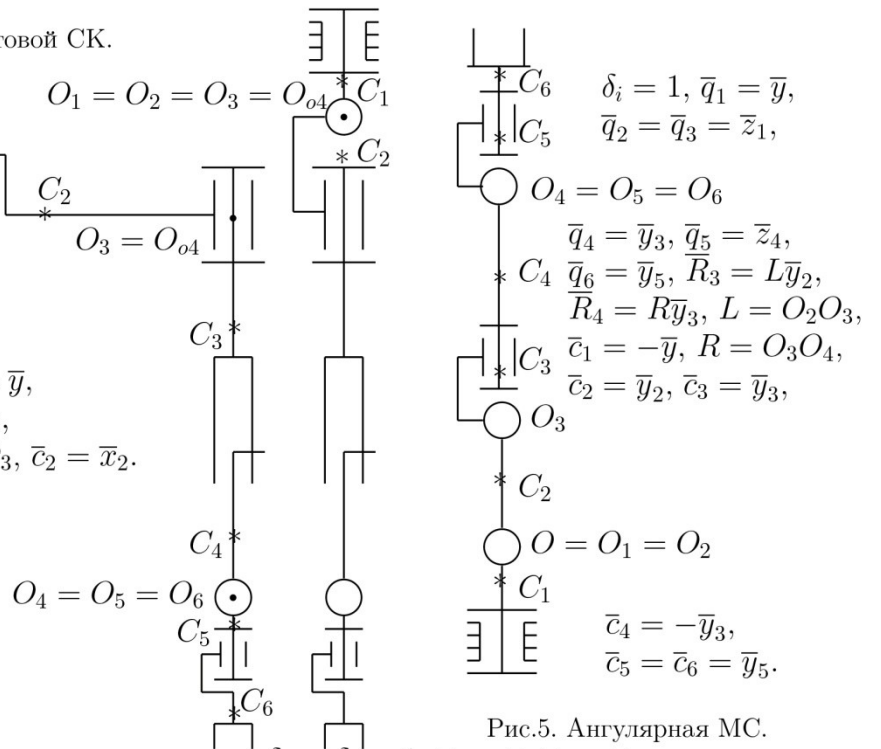


Рис.5. Ангулярная МС.

Рис.4. МС с сферической СК.

$$\bar{m}_k = a_k \bar{c}_k + m_{k+1} \bar{R}_{k+1} + \bar{m}_{k+1}; \quad k = N, N-1, \dots, 1; \quad \bar{m}_{N+1} = 0; \quad \bar{R}_{N+1} = 0; \quad m_{N+1} = 0. \quad (2)$$

$$G_k = g(\delta_k m_k \bar{y} \cdot \bar{p}_k + \delta_k \bar{y} \cdot \bar{q}_k \times \bar{m}_k); \quad k = 1, 2, \dots, N; \quad \delta_k = 1 - \delta_k. \quad (3)$$

$$J_k^q = I_k^q - \sum_{i=k}^N I_{\zeta_i}^q (\bar{q}_k \cdot \bar{\zeta}_i)^2 + \sum_{i=k+1}^N [m_i R_i^2 \sin^2(\bar{q}_k, \bar{R}_i) + 2(\bar{R}_i - \bar{R}_i \cdot \bar{q}_k \bar{q}_k) \cdot \bar{m}_i]; \quad I_k^q = \sum_{i=k}^N I_i^q. \quad (4)$$

$$H_{kj} = \delta_k \delta_j m_k \bar{p}_j \cdot \bar{p}_k + \delta_k \delta_j \bar{p}_k \cdot \bar{q}_j \times \bar{m}_{jk} + \delta_k \delta_j \bar{p}_j \cdot \bar{q}_k \times \bar{m}_k + \delta_k \delta_j \{I_{\zeta_i}^q \bar{q}_j \cdot \bar{q}_k - \sum_{i=k}^N I_{\zeta_i}^q \bar{q}_k \cdot \bar{\zeta}_i \bar{q}_j \cdot \bar{\zeta}_i + \\ + \bar{q}_j \cdot (\bar{q}_k \bar{m}_k - \bar{m}_k \bar{q}_k) \cdot \bar{R}_{jk} + \sum_{i=k+1}^N [m_i (R_i^2 \bar{q}_j \cdot \bar{q}_k - R_{ik}^q R_{ij}^q) + (2\bar{q}_j \cdot \bar{q}_k \bar{R}_i - R_{ik}^q \bar{q}_j - R_{ij}^q \bar{q}_k) \cdot \bar{m}_i]\}. \quad (5)$$

$$J_j^q = J_k^q + \sum_{i=j}^{k-1} [I_i^q - I_{\zeta_i}^q (\bar{q}_j \cdot \bar{\zeta}_i)^2] + \sum_{i=j+1}^k [m_i R_i^2 \sin^2(\bar{q}_j, \bar{R}_i) + 2(\bar{R}_i - \bar{R}_i \cdot \bar{q}_j \bar{q}_i) \cdot \bar{m}_i]. \quad (6)$$

$$H_{kj} = J_k^q + \bar{q}_j \cdot (\bar{q}_k \bar{m}_k - \bar{m}_k \bar{q}_k) \cdot \bar{R}_{jk}; \quad H_{ki} = H_{kj} + \bar{q}_j \cdot (\bar{q}_k \bar{m}_k - \bar{m}_k \bar{q}_k) \cdot \bar{R}_{ij}. \quad (7)$$

$$\bar{m}_6 = -a_6 \bar{y}_5; \quad \bar{m}_5 = -a \bar{y}_5; \quad \bar{m}_4 = a_4 \bar{y}_3 - a \bar{y}_5; \quad \bar{m}_3 = m_{q4} \bar{y}_3 - a \bar{y}_5. \quad (8)$$

$$\bar{m}_6 = a_6 \bar{y}_5; \quad \bar{m}_5 = a \bar{y}_5; \quad \bar{m}_4 = -a_4 \bar{y}_3 + a \bar{y}_5; \quad \bar{m}_3 = b \bar{y}_3 + a \bar{y}_5; \quad \bar{m}_2 = c \bar{y}_2 + b \bar{y}_3 + a \bar{y}_5. \quad (9)$$

$$\begin{pmatrix} \eta_{ji-1}^x \\ \eta_{ji-1}^y \\ \eta_{ji-1}^z \end{pmatrix} = \begin{cases} \left(\eta_{ji}^x, c_i \eta_{ji}^y - s_i \eta_{ji}^z, s_i \eta_{ji}^y + c_i \eta_{ji}^z \right)^T, & \text{if } \bar{q}_i = \bar{x}_i, \\ \left(c_i \eta_{ji}^x + s_i \eta_{ji}^z, \eta_{ji}^y, -s_i \eta_{ji}^x + c_i \eta_{ji}^z \right)^T, & \text{if } \bar{q}_i = \bar{y}_i, \\ \left(c_i \eta_{ji}^x - s_i \eta_{ji}^y, s_i \eta_{ji}^x + c_i \eta_{ji}^y, \eta_{ji}^z \right)^T, & \text{if } \bar{q}_i = \bar{z}_i, \end{cases} \quad \begin{pmatrix} \eta_{jj}^x \\ \eta_{jj}^y \\ \eta_{jj}^z \end{pmatrix} = \begin{cases} (1, 0, 0)^T & \text{if } \eta = x, \\ (0, 1, 0)^T & \text{if } \eta = y, \\ (0, 0, 1)^T & \text{if } \eta = z. \end{cases} \quad (10)$$

$$G_5 = -agx_5^y, \quad G_4 = ags_5 z_4^y, \quad G_3 = g\bar{y} \cdot \bar{z}_1 \times \bar{m}_3, \quad G_2 = g\bar{y} \cdot \bar{z}_1 \times (c\bar{y}_2 + \bar{m}_3) = G_3 - cg\bar{y} \cdot \bar{x}_1. \quad (11)$$

$$J_3^q = I_3^x + I_4^x + I_5^x + I_6^x - I_{y_3}^x (\bar{y}_3 \cdot \bar{y}_3)^2 - I_{y_4}^x (\bar{y}_3 \cdot \bar{y}_3)^2 - I_{y_5}^x (\bar{y}_3 \cdot \bar{y}_5)^2 - I_{y_6}^x (\bar{y}_3 \cdot \bar{y}_6)^2 + \\ + m_4 q_4^2 \sin^2(\bar{y}_3, \bar{y}_3) - 2q_4 (\bar{y}_3 \cdot \bar{y}_3 \cdot \bar{y}_3 \bar{y}_3) \cdot \bar{m}_4 = I_3^y + I_4^y + I_5^y + I_6^y - (I_{y_3}^x + I_{y_3}^y) c_5^2 = I_a - I_b c_5^2. \quad (12)$$

$$H_{63} = I_6^q \bar{y}_5 \cdot \bar{y}_3 - I_{y_6}^x \bar{y}_5 \cdot \bar{y}_6 \bar{y}_3 \cdot \bar{y}_6 + \bar{y}_3 \cdot (\bar{y}_6 \bar{m}_6 - \bar{m}_6 \bar{y}_6) \cdot (-q_4 \bar{y}_3) = I_6^y c_5;$$

$$H_{54} = \bar{p}_4 \cdot \bar{q}_5 \times \bar{m}_5 = a \bar{y}_3 \cdot \bar{z}_3 \times \bar{y}_5 = a \bar{x}_3 \cdot \bar{y}_5 = -a s_5;$$

$$H_{53} = I_5^q \bar{z}_3 \cdot \bar{y}_3 - I_{y_5}^x \bar{z}_3 \cdot \bar{y}_5 \bar{y}_3 \cdot \bar{y}_5 - I_{y_6}^x \bar{z}_3 \cdot \bar{y}_6 \bar{y}_3 \cdot \bar{y}_6 - \bar{y}_3 \cdot (\bar{q}_5 \bar{m}_5 - \bar{m}_5 \bar{q}_5) \cdot (-q_4 \bar{y}_3) = 0. \quad (13)$$

$$\begin{pmatrix} \delta_1 m_1 + \delta_1 J_1^q & H_{21} & I_2^z & H_{41} & H_{51} & H_{61} \\ H_{21} & \delta_2 m_2 + \delta_2 J_2^q & H_{32} & H_{42} & H_{52} & H_{62} \\ H_{31} & H_{32} & I_a - I_b c_5^2 & 0 & 0 & I_6^y c_5 \\ H_{41} & H_{42} & 0 & m_4 & -a s_5 & 0 \\ H_{51} & H_{52} & 0 & -a s_5 & I_5^q & 0 \\ H_{61} & H_{62} & I_6^y c_5 & 0 & 0 & I_6^y \end{pmatrix} \quad (14)$$

$$J_2^q = J_3^q + I_2^z - I_{x_2}^z (\bar{y} \cdot \bar{x}_2)^2 + m_3 L_2^2 + 2L_2 \bar{x}_2 \cdot (m_{q4} \bar{y} - a \bar{y}_5) = J_3^q + I_2^z + m_3 L_2^2 + 2L_2 a c_3 s_5. \quad (15)$$

$$J_1^q = J_2^q + I_1^z - I_{x_1}^z (\bar{y} \cdot \bar{x}_1)^2 + m_2 L_1^2 + 2L_1 \bar{x}_1 \cdot (b \bar{x}_2 + m_{q4} \bar{y} - a \bar{y}_5) = J_2^q + I_1^z + m_2 L_1^2 + 2L_1 b c_2 - 2L_1 a y_{51}^x. \quad (16)$$

$$H_{62} = H_{63} + \bar{q}_3 \cdot (\bar{q}_6 \bar{m}_6 - \bar{m}_6 \bar{q}_6) \cdot \bar{R}_{23} = H_{63} - a_6 \bar{q}_3 \cdot (\bar{y}_5 \bar{y}_5 - \bar{y}_5 \bar{y}_5) \cdot \bar{R}_{23} = H_{63}; \quad H_{61} = H_{62} + \\ + \bar{q}_2 \cdot (\bar{q}_6 \bar{m}_6 - \bar{m}_6 \bar{q}_6) \cdot \bar{R}_{12} = H_{62}; \quad H_{52} = H_{53} + \bar{q}_3 \cdot (\bar{q}_5 \bar{m}_5 - \bar{m}_5 \bar{q}_5) \cdot \bar{R}_{23} = -a \bar{y} \cdot (\bar{z}_3 \bar{y}_5 - \bar{y}_5 \bar{z}_3) \cdot (L_2 \bar{x}_2) = \\ = a L_2 \bar{y} \cdot \bar{y}_5 \bar{z}_3 \cdot \bar{x}_2 = a L_2 c_5 s_3; \quad H_{51} = H_{52} + \bar{q}_2 \cdot (\bar{q}_5 \bar{m}_5 - \bar{m}_5 \bar{q}_5) \cdot \bar{R}_{12} = H_{52} + a L_1 \bar{y} \cdot \bar{y}_5 \bar{z}_3 \cdot \bar{x}_1. \quad (17)$$

$$H_{32} = J_3^q + \bar{q}_2 \cdot (\bar{q}_3 \bar{m}_3 - \bar{m}_3 \bar{q}_3) \cdot \bar{R}_{23} = J_3^q + L_2 \bar{m}_3 \cdot \bar{x}_2 = \dots; \quad H_{21} = J_2^q + \bar{q}_1 \cdot (\bar{q}_2 \bar{m}_2 - \bar{m}_2 \bar{q}_2) \cdot \bar{R}_{12} = \dots. \quad (18)$$

Рис. 6. Формулы выписывания статических моментов подсистем, ОСТ и инерционных коэффициентов МС.

МИК МС на рис. 1

$$\begin{pmatrix} m_1 & 0 & H_{31} & 0 & H_{51} & 0 \\ 0 & m_2 & H_{32} & 0 & H_{52} & 0 \\ -ac_3s_5 & -as_3s_5 & I_a - I_b c_5^2 & 0 & 0 & H_{63} \\ 0 & 0 & 0 & m_4 & H_{54} & 0 \\ -as_3c_5 & ac_3c_5 & 0 & -as_5 & I_5^q & 0 \\ 0 & 0 & I_6^y c_5 & 0 & 0 & I_6^y \end{pmatrix}.$$

МИК МС на рис. 2

$$\begin{pmatrix} I_c - I_b c_5^2 + m_2 q_2^2 + 2q_2(ac_3s_5 - a_2) & H_{21} & H_{31} & 0 & H_{51} & H_{61} \\ -as_3s_5 & m_2 & H_{32} & 0 & H_{52} & 0 \\ J_3^q + aq_2c_3s_5 & -as_3s_5 & I_a - I_b c_5^2 & 0 & 0 & H_{63} \\ 0 & 0 & 0 & m_4 & H_{54} & 0 \\ aq_2s_3c_5 & ac_3c_5 & 0 & -as_5 & I_5^q & 0 \\ I_6^y c_5 & 0 & I_6^y c_5 & 0 & 0 & I_6^y \end{pmatrix},$$

где $I_a = I_3^y + I_4^y + I_5^q$, $I_b = I_{y5}^x + I_{y6}^x$, $I_c = I_a + I_1^y + I_2^z$, $s_i = \sin(q_i)$, $c_i = \cos(q_i)$.

МИК МС на рис. 3

$$\begin{pmatrix} I_e - I_b c_5^2 + 2bL_1c_2 + 2as_5(L_2c_3 + L_1c_{23}) & H_{21} & H_{31} & 0 & H_{51} & H_{61} \\ J_2^q + L_1(bc_2 + as_5c_{23}) & I_e - I_b c_5^2 + 2aL_2c_3s_5 & H_{32} & 0 & H_{52} & 0 \\ J_3^q + a(L_2c_3 + L_1c_{23})s_5 & J_3^q + aL_2c_3s_5 & I_a - I_b c_5^2 & 0 & 0 & H_{63} \\ 0 & 0 & 0 & m_4 & H_{54} & 0 \\ ac_5(L_2s_3 + L_1s_{23}) & aL_2s_3c_5 & 0 & -as_5 & I_5^q & 0 \\ I_6^y c_5 & I_6^y c_5 & I_6^y c_5 & 0 & 0 & I_6^y \end{pmatrix},$$

где $I_d = I_a + I_2^z + m_3L^2$, $I_e = I_d + I_1^z + m_2L_1^2$, $s_{23} = \sin(q_2 + q_3)$, $c_{23} = \cos(q_2 + q_3)$.

МИК МС на рис. 4

$$\begin{pmatrix} J_1^q & H_{21} & H_{31} & 0 & H_{51} & H_{61} \\ -(I_b y_{51}^y + aq_4c_2)s_3s_5 & I_2^q - I_b s_3^2 s_5^2 + m_4 q_4^2 - 2q_4(a_4 - ac_5) & H_{32} & 0 & H_{52} & H_{62} \\ I_a c_2 - I_b c_5 y_{51}^y + aq_4s_2c_3s_5 & -(I_b c_5 + aq_4)s_3s_5 & I_a - I_b c_5^2 & 0 & 0 & H_{63} \\ -as_2s_3s_5 & -ac_3s_5 & 0 & m_4 & H_{54} & 0 \\ (I_5^q + aq_4c_5)s_2s_3 & (I_5^q + aq_4c_5)c_3 & 0 & -as_5 & I_5^q & 0 \\ I_6^y y_{51}^y & I_6^y s_3s_5 & I_6^y c_5 & 0 & 0 & I_6^y \end{pmatrix},$$

где $y_{51}^y = c_2c_5 - s_2c_3s_5$.

МИК МС на рис. 5

$$\begin{pmatrix} J_1^q & H_{21} & H_{31} & H_{41} & H_{51} & H_{61} \\ -(I_b y_{51}^y + Ac_2 + Bc_{23})s_4s_5 & J_3^q + I_g + 2(Dc_3 + Ay_{52}^y) & H_{32} & H_{42} & H_{52} & H_{62} \\ -(I_b y_{51}^y + Bc_{23})s_4s_5 & J_3^q + L(ay_{52}^y - a_4c_3) & I_f + 2Bc_5 - I_b s_4^2 s_5^2 & H_{43} & H_{53} & H_{63} \\ [As_2 + (B + I_b c_5)s_{23}]c_4s_5 + J_4^q c_{23} & H_{43} - Ac_3s_4s_5 & -(B + I_b c_5)s_4s_5 & I_h - I_b c_5^2 & 0 & H_{64} \\ [(I_5^q + Bc_5)s_{23} + As_2c_5]s_4 & H_{53} + A(c_3c_4c_5 - s_3s_5) & (I_5^q + Bc_5)c_4 & 0 & I_5^q & 0 \\ I_6^y (c_{23}c_5 - s_{23}c_4s_5) & I_6^y s_4s_5 & I_6^y s_4s_5 & I_6^y c_5 & 0 & I_6^y \end{pmatrix}$$

где $J_1^q = I_1^y + I_2^q - I_{y2}^x c_2^2 - (I_{y3}^x + I_{y4}^x)c_{23}^2 - I_b (y_{51}^y)^2 + m_3L^2s_2^2 + m_4R^2s_{23}^2 + 2L[bc_3 + ay_{52}^y - c_2(bc_{23} + ay_{51}^y)] + 2R[ac_5 - a_4 - c_{23}(ay_{51}^y - a_4c_{23})]$, $A = aL$, $B = aR$, $D = bL$, $I_f = I_3^q + m_4R^2 - 2Ra_4$, $I_g = I_2^x + m_3L^2$, $I_h = I_4^y + I_5^q$, $y_{51}^y = c_{23}c_5 - s_{23}c_4s_5$, $y_{52}^y = c_3c_5 - s_3c_4s_5$.

Рис. 7 Матрицы инерционных коэффициентов (МИК) МС

$$h_k = \delta_k J_k^q \dot{q}_k + \sum_{i=1}^{k-1} (\dot{H}_{ki} \dot{q}_i - 0.5 \delta_i \dot{q}_i^2 \partial J_i^q / \partial q_k) + \sum_{j=k+1}^N \dot{H}_{jk} \dot{q}_j - \sum_{j=2}^N \dot{q}_j \sum_{i=1}^{j-1} \dot{q}_i \partial H_{ji} / \partial q_k. \quad (19)$$

$$T = 0.5 \sum_{j=1}^N [(\hat{\delta}_j m_j + \delta_j J_j^q) \dot{q}_j^2 + 2 \dot{q}_j \sum_{i=1}^{j-1} H_{ji} \dot{q}_i]; \quad \partial T / \partial \dot{q}_k = (\hat{\delta}_k m_k + \delta_k J_k^q) \dot{q}_k + \sum_{i=1}^{k-1} H_{ki} \dot{q}_i + \sum_{j=k+1}^N H_{jk} \dot{q}_j;$$

$$d(\partial T / \partial \dot{q}_k) / dt = (\hat{\delta}_k m_k + \delta_k J_k^q) \ddot{q}_k + \sum_{i=1}^{k-1} \dot{H}_{ki} \dot{q}_i + \sum_{j=k+1}^N \dot{H}_{jk} \ddot{q}_j + \delta_k J_k^q \dot{q}_k + \sum_{i=1}^{k-1} \dot{H}_{ki} \dot{q}_i + \sum_{j=k+1}^N \dot{H}_{jk} \dot{q}_j;$$

$$\partial T / \partial q_k = 0.5 \sum_{j=1}^{k-1} \delta_j \dot{q}_j^2 \partial J_j^q / \partial q_k + \sum_{j=2}^N \dot{q}_j \sum_{i=1}^{j-1} \dot{q}_i \partial H_{ji} / \partial q_k. \quad (20)$$

$$h_k = \delta_k J_k^q \dot{q}_k + \sum_{i=1}^{k-1} \dot{H}_{ki} \dot{q}_i + \sum_{i=k+1}^N \dot{H}_{ik} \dot{q}_i. \quad (21)$$

$$h_1 = \dot{H}_{31} \dot{q}_3 + \dot{H}_{51} \dot{q}_5 = -a(-s_3 s_5 \dot{q}_3 + c_3 c_5 \dot{q}_5) \dot{q}_3 - a(c_3 c_5 \dot{q}_3 - s_3 s_5 \dot{q}_5) \dot{q}_5 = a[s_3 s_5 (\dot{q}_3^2 + \dot{q}_5^2) - 2c_3 c_5 \dot{q}_3 \dot{q}_5];$$

$$h_2 = \dot{H}_{32} \dot{q}_3 + \dot{H}_{52} \dot{q}_5 = -a(c_3 s_5 \dot{q}_3 + s_3 c_5 \dot{q}_5) \dot{q}_3 - a(s_3 c_5 \dot{q}_3 + c_3 s_5 \dot{q}_5) \dot{q}_5 =$$

$$= -a[c_3 s_5 (\dot{q}_3^2 + \dot{q}_5^2) + 2s_3 c_5 \dot{q}_3 \dot{q}_5]. \quad (22)$$

$$h_3 = J_3^q \dot{q}_3 + \dot{H}_{31} \dot{q}_1 + \dot{H}_{32} \dot{q}_2 + \dot{H}_{63} \dot{q}_6 - \dot{q}_3 (\dot{q}_1 \partial H_{31} / \partial q_3 + \dot{q}_2 \partial H_{32} / \partial q_3) - \dot{q}_5 (\dot{q}_1 \partial H_{51} / \partial q_3 + \dot{q}_2 \partial H_{52} / \partial q_3) = 2I_b c_5 s_5 \dot{q}_5 \dot{q}_3 - a(-s_3 s_5 \dot{q}_3 + c_3 c_5 \dot{q}_5) \dot{q}_1 - a(c_3 s_5 \dot{q}_3 + s_3 c_5 \dot{q}_5) \dot{q}_2 -$$

$$- I_6^y s_5 \dot{q}_6 \dot{q}_3 - a \dot{q}_3 (\dot{q}_1 s_3 s_5 - c_3 s_5 \dot{q}_2) - a \dot{q}_5 (-\dot{q}_1 c_3 c_5 - \dot{q}_2 s_3 c_5) = (2I_b c_5 \dot{q}_3 - I_6^y \dot{q}_6) s_5 \dot{q}_5;$$

$$h_5 = \dot{H}_{51} \dot{q}_1 + \dot{H}_{52} \dot{q}_2 + \dot{H}_{54} \dot{q}_4 - 0.5 \dot{q}_5^2 \partial J_5^q / \partial q_5 - \dot{q}_3 (\dot{q}_1 \partial H_{31} / \partial q_5 + \dot{q}_2 \partial H_{32} / \partial q_5) - \dot{q}_5 (\dot{q}_1 \partial H_{51} / \partial q_5 + \dot{q}_2 \partial H_{52} / \partial q_5 + \dot{q}_4 \partial H_{54} / \partial q_5) - \dot{q}_6 (\dot{q}_3 \partial H_{63} / \partial q_5) = -a(c_3 c_5 \dot{q}_3 - s_3 s_5 \dot{q}_5) \dot{q}_1 - a(s_3 c_5 \dot{q}_3 + c_3 s_5 \dot{q}_5) \dot{q}_2 -$$

$$- ac_5 \dot{q}_5 \dot{q}_4 - I_b c_5 s_5 \dot{q}_3^2 - a \dot{q}_3 (-\dot{q}_1 c_3 c_5 - \dot{q}_2 s_3 c_5) - a \dot{q}_5 (\dot{q}_1 s_3 s_5 - \dot{q}_2 c_3 s_5 - \dot{q}_4 c_5) + I_6^y s_5 \dot{q}_3 \dot{q}_6 =$$

$$= (I_6^y \dot{q}_6 - I_b c_5 \dot{q}_3) s_5 \dot{q}_3. \quad (23)$$

УД МС на рис. 1

$$\begin{cases} m_1 \ddot{q}_1 - ac_3 s_5 \ddot{q}_3 - as_3 c_5 \ddot{q}_5 + a[s_3 s_5 (\dot{q}_3^2 + \dot{q}_5^2) - 2c_3 c_5 \dot{q}_3 \dot{q}_5] = F_1 \\ m_2 \ddot{q}_2 - as_3 s_5 \ddot{q}_3 + ac_3 c_5 \ddot{q}_5 - a[c_3 s_5 (\dot{q}_3^2 + \dot{q}_5^2) + 2s_3 c_5 \dot{q}_3 \dot{q}_5] = F_2 \\ -ac_3 s_5 \ddot{q}_1 - as_3 s_5 \ddot{q}_2 + (I_a - I_b c_5^2) \ddot{q}_3 + I_6^y c_5 \ddot{q}_6 + s_5 (2I_b c_5 \dot{q}_3 - I_6^y \dot{q}_6) \dot{q}_5 = M_3 \\ m_4 \ddot{q}_4 - as_5 \ddot{q}_5 - ac_5 \dot{q}_5^2 - m_4 g = F_4 \\ -as_3 c_5 \ddot{q}_1 + ac_3 c_5 \ddot{q}_2 - as_5 \ddot{q}_4 + I_5^q \ddot{q}_5 + s_5 (I_6^y \dot{q}_6 - I_b c_5 \dot{q}_3) \dot{q}_3 + ag s_5 = M_5 \\ I_6^y c_5 \ddot{q}_3 + I_6^y \ddot{q}_6 - I_6^y s_5 \dot{q}_3 \dot{q}_5 = M_6, \end{cases}$$

где $h_{33} = I_b c_5 s_5 \dot{q}_3 \dot{q}_5 + h_{g3}$, $h_5 = h_{g5} = s_5 (I_6^y \dot{q}_6 - I_b c_5 \dot{q}_3) \dot{q}_3$, $h_{g3} = s_5 (I_b c_5 \dot{q}_3 - I_6^y \dot{q}_6) \dot{q}_5$, так как $h_{g3} \dot{q}_3 + h_{g5} \dot{q}_5 = s_5 (I_b c_5 \dot{q}_3 - I_6^y \dot{q}_6) \dot{q}_5 \dot{q}_3 + s_5 (I_6^y \dot{q}_6 - I_b c_5 \dot{q}_3) \dot{q}_3 \dot{q}_5 = 0$.

УД МС на рис. 2

$$\begin{cases} [I_c - I_b c_5^2 + m_2 \dot{q}_2^2 + 2q_2 (ac_3 s_5 - a_2)] \ddot{q}_1 - as_3 s_5 \ddot{q}_2 + (J_3^q + aq_2 c_3 s_5) \ddot{q}_3 + aq_2 s_3 c_5 \dot{q}_5 + I_6^y c_5 \dot{q}_6 + h_1 = M_1 \\ -as_3 s_5 \ddot{q}_1 + m_2 \ddot{q}_2 - as_3 s_5 \ddot{q}_3 + ac_3 c_5 \ddot{q}_5 + h_{c2} - 2a(c_3 s_5 \dot{q}_1 \dot{q}_3 + s_3 c_5 \dot{q}_1 \dot{q}_5) = F_2 \\ (J_3^q + aq_2 c_3 s_5) \ddot{q}_1 - as_3 s_5 \ddot{q}_2 + (I_a - I_b c_5^2) \ddot{q}_3 + I_6^y c_5 \dot{q}_6 + h_3 = M_3 \\ m_4 \ddot{q}_4 - as_5 \ddot{q}_5 - ac_5 \dot{q}_5^2 - m_4 g = F_4 \\ aq_2 s_3 c_5 \ddot{q}_1 + ac_3 c_5 \ddot{q}_2 - as_5 \ddot{q}_4 + I_5^q \ddot{q}_5 + h_{c5} + 2c_5 (I_b s_5 \dot{q}_3 + as_3 \dot{q}_2) \dot{q}_1 - ac_5 \dot{q}_4 \dot{q}_5 + I_6^y s_5 \dot{q}_1 \dot{q}_3 \dot{q}_6 + ag s_5 = M_5 \\ I_6^y c_5 \ddot{q}_1 + I_6^y c_5 \ddot{q}_3 + I_6^y \ddot{q}_6 - I_6^y s_5 \dot{q}_1 \dot{q}_3 \dot{q}_5 = M_6, \end{cases}$$

где $h_{c2} = (a_2 - m_2 \dot{q}_2 - ac_3 s_5) \dot{q}_1^2 - ac_3 s_5 (\dot{q}_3^2 + \dot{q}_5^2)$, $h_{c5} = c_5 (I_b s_5 - aq_2 c_3) \dot{q}_1^2 + I_b s_5 c_5 \dot{q}_3^2$, $\dot{q}_{13} = \dot{q}_1 + \dot{q}_3$.

Рис. 8. Формулы вывода ОИС и УД МС

Библиографический список

1. Н. Delavari, R. Ghaderi, A. Ranjbar N., S.H. HosseinNia, S. Momani. Adaptive Fractional PID Controller for Robot Manipulator // Proceedings of FDA'10. The 4th IFAC Workshop Fractional Differentiation and its Applications. Badajoz, Spain, October 18–20, 2010, pp.1-7.

2. Elbrous M. Jafarov, Yorgo Istefanopulos, M.N. Alpaslan Parlakçi. A new variable structure PID-controller for robot manipulators with parameter perturbations: an augmented sliding surface approach // 15th Triennial World Congress, Barcelona, Spain, 2002, pp. 365–370.
3. JianXuandLeiQi. Robust Adaptive PID Control of Robot Manipulator with Bounded Disturbances // Hindawi Publishing Corporation Mathematical Problems in Engineering, Volume October, 2013, pp. 1–13.
4. Huang Chunqing, Shi Songjiao. PID feedback for mixed Hi/Hco tracking control of robotic manipulators // Journal of Systems Engineering and Electronics, Vol .15, No.4, 2004, pp. 579–585.
5. Erkan Kayacan, Erdal Kayacan, Herman Ramon, Wouter Saeys. Velocity Control of a Spherical Rolling Robot Using a Grey-PID Type Fuzzy Controller With an Adaptive Step Size // 10th IFAC Symposium on Robot Control International Federation of Automatic Control. Dubrovnik, Croatia, September 5-7, 2012, pp. 863–868.
6. Nasr M. Ghaleb, Ayman A. Aly. Modeling and Control of 2-DOF Robot Arm // International Journal of Emerging Engineering Research and Technology, Volume 6, Issue 11, 2018, pp. 24–31.
7. Adam Tan Mohd Amina, Abdul Hakim Ab Rahima, Cheng YeeLowa. Adaptive controller algorithm for 2-DOF humanoid robot arm // Procedia Technology, 15 (2014), pp. 765–774, www.sciencedirect.com.
8. Телегин А.И. Уравнения математических моделей механических систем: Учебное пособие. // Челябинск: Изд. ЮУрГУ, 1999. – 181 с.
9. Телегин, А.И. Алгоритмы решения первой задачи динамики для плоских рычажных механизмов / А.И. Телегин, М.В. Тимощенко // Вестник ЮУрГУ. Серия “Машиностроение”, 2007, Вып.10. №25(97), С. 12–22.
10. Телегин А.И. Новый векторный вид уравнений динамики систем тел // Вестник ЮУрГУ, серия “Машиностроение”, 2014, Т.14. №1, С. 33–40.
11. Лурье А.И. Аналитическая механика. // М.: Физматгиз, 1961, 824 с.

SIX DEGREE OF FREEDOM MANIPULATOR DYNAMICS EQUATIONS

Telegin Alexander Ivanovich, Pudovkina Svetlana Gennadievna

Branch of the Federal State Autonomous Educational Institution of Higher Education "South Ural State University (National Research University)" in Miass
456318, Russia, Chelyabinsk Region, Miass, October Avenue, 16,
pudovkinasg@susu.ru

The article solves the problem of bulkiness for the equations of dynamics (ED) of bodies' systems with many degrees of freedom. The new formalism of output of industrial robots manipulation systems (MS) consisting of translational (TKP) and rotary (RKP) kinematic pairs (KP) is proposed. Five examples of output of MS ED with six bodies operating in Cartesian, cylindrical, spherical and angular coordinate systems (CS) are given. Geometric, kinematic, static and inertial

parameters of the MS are explicitly expressed in the obtained ED. According to the known classical formalisms (Lagrange, Appel, Nielsen, Newton-Euler, etc.), it is almost impossible to obtain similar results due to the large number of complex mathematical operations in their implementation and the bulkiness of the resulting formulas. In this article multipliers at accelerations and velocity products are optimal in terms of the minimum of arithmetic operations (additions and multiplications) necessary for their calculations. The analytical types of ED which are given in this article occupy several lines, unlike dozens of pages of typewritten text in the EDs which are obtained, for example, according to the Lagrange formalism.

Key words: industrial robots, equations of dynamics, formalisms of writing out, reuse of formulas.

УДК 519.7

МЕДИЦИНА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ

Фиговский Олег Львович

Ассоциация Изобретателей Израиля, Хайфа, Израиль, figovsky@gmail.com

Статья посвящена описанию разработки КОВИД 19. В статье рассказывается о некоторых достижениях искусственного интеллекта в борьбе с пандемией.

Ключевые слова: пандемия, искусственный интеллект, медицина, применение искусственного интеллекта, проекты.

Введение

На момент написания статьи мировую систему здравоохранения, а вместе с ней и всю экономику цивилизованного мира, где здравоохранение является значимым элементом структуры, «проверяет на прочность» эпидемия коронавируса COVID-19. Потому обзор последних достижений человечества в медицинской отрасли стоит начать с сообщений о битве человека с COVID-19.

COVID-19. Начало

31 декабря 2019 года весь цивилизованный мир готовился к встрече нового 2020 года, и мало кто обратил внимание на сообщение, что в китайском городе Ухань госпитализированы 27 человек с диагнозом «пневмония неизвестного происхождения», 7 из них находятся в критическом состоянии. Эксперты Государственного комитета по вопросам здравоохранения Китая, успокоили мировую общественность, заявив, что угрозы пандемии пока нет, и пообещали в сжатые сроки выяснить происхождение новой болезни. Но Роспотребнадзор был начеку и предупредил российских граждан об угрозе заболеть пневмонией при поездке в Китай. 9 января китайские эпидемиологи сообщили, что установлено – возбудителем вспышки пневмонии в Ухане стал новый вид

коронавируса. 11 января китайцы сообщили о первом умершем от нового типа коронавируса. На тот день по предварительным данным, был выявлен 41 случай заражения новым типом коронавируса, двое заболевших были выписаны из больницы, а состояние остальных пациентов оценивалось как стабильное. Под медицинским наблюдением находились 739 человек, из них 419 – медики, которые контактировали с больными. 20 января из Китая пришло сообщение, что коронавирус нового типа может передаваться от человека к человеку. Число заболевших увеличилось до 217 человек. В тот же день в Южной Корее сообщили, что пневмонией, вызванной новым типом коронавируса, заболела женщина, которая приехала из Уханя. Через день американские СМИ со ссылкой на Центр по контролю и профилактике заболеваний США опубликовали сообщение, что в стране зафиксирован первый случай заболевания коронавирусом. Заболевший – мужчина, который недавно вернулся из Китая. 22 января заместитель главы Государственного комитета по вопросам гигиены и здравоохранения КНР Ли Бинь заявил: «Существует риск прогрессирующего распространения заболевания». В переводе на обывательский язык это означало, что есть угроза глобальной эпидемии. Также было сообщено, что основной канал заражения – воздушно-капельный. С утра 23 января жителям Уханя, ставшего эпицентром вспышки коронавируса, было предписано не покидать город без особых причин. Такими мерами власти Китая пытались ограничить распространение коронавируса. Работа общественного транспорта Уханя, метро, паромов и поездов дальнего следования была прекращена, вылет из аэропорта закрыт. Но процесс распространения нового коронавируса по планете было уже не остановить. 24 января были официально подтверждены два случая заражения новым коронавирусом во Франции. Это означало, что коронавирус проник в Европу. 25 января больной коронавирусом был выявлен в Австралии. 26 января пришла очередь Северной Америки – первый случай заражения новым коронавирусом был зафиксирован в Канаде. 30 января Всемирная организация здравоохранения (ВОЗ) объявила вспышку коронавируса 2019-nCoV «чрезвычайной ситуацией в области общественного здравоохранения, имеющей международное значение». 11 февраля новый коронавирус получил официальное название – COVID-19. Рецепт борьбы с новой заразой от современной медицины стал простой – самоизоляция, ограничение контактов, соблюдение правил личной гигиены.

COVID-19. Послесловие

Нагрянувший к нам неведомо откуда, то ли из дикой природы, то ли из секретных лабораторий, коронавирус, в считанные дни обрушивший мировую экономику, заставляет задуматься о векторах развития нашей цивилизации. Чтобы не оказаться побежденными в такой катавасии, представителям рода человеческого надобно пересмотреть свои подходы к жизни. В частности, к инновациям. Особенно в той их части, которая касается внедрения. Необходимо проработать методики ускоренного доведения до производства задумок ученых и разработок инженеров. Инновационные системы должны работать быстро. Скорость внедрения

инноваций может оказаться определяющим фактором в критических ситуациях. И ИИИ (изобретающий искусственный интеллект) является одним из элементов, ускоряющих выведение инноваций на орбиту потребностей всего человечества.

Как современные интеллектуальные системы помогают врачам бороться с коронавирусом

Израильская компания RADLogics заявила о разработке автоматизированной программы выявления COVID-19 на основе анализа компьютерной томографии. Помимо мгновенной диагностики, она обладает высокой точностью результата и позволяет отслеживать, как протекает заболевание, уверяют разработчики. «Используя для анализа снимков алгоритмы глубинного обучения, RADLogics достиг 98,2% чувствительности (вероятность правильной диагностики больных пациентов) и 92,2% специфичности (вероятность правильной диагностики здоровых пациентов)», – говорится в заявлении компании. Исследования проводились на основе данных о 157 пациентах из Китая и США. Для анализа 400 снимков компьютерной томографии платформе понадобилось 30 секунд. Для пациентов с коронавирусом система выводит количественные показатели снижения прозрачности легочной ткани, а также визуализирует большие помутнения на «тепловой карте» легких, как на плоских снимках в разрезе, так и в трехмерном формате. Введенный RADLogics количественный «индекс коронавируса» позволяет измерять динамику заболевания с течением времени. Разработанный в сжатые сроки алгоритм способен применяться как для диагностики коронавируса, так и для количественного анализа и мониторинга динамики заболевания.

Ученым из Медицинского центра Маунт-Синай удалось быстро разработать уникальный алгоритм для оценки снимков легких при подозрении на коронавирусную инфекцию. Его точность оказалась на уровне опытных рентгенологов, а в спорных случаях ИИ был намного точнее врачей.

Работа американских ученых служит наглядным примером быстрого внедрения технологий искусственного интеллекта для спасения жизни людей. В условиях пандемии они обучили ИИ определять изменения в легких по снимкам компьютерной томографии, чтобы быстро предоставить врачу второе мнение при постановке диагноза. Однако оказалось, что без явных повреждений на снимках ИИ мог лучше врача находить COVID-19. Обучение ИИ проводилось с помощью медицинских данные более 900 пациентов из Китая, у которых подозревали COVID-19. У 419 из них вскоре подтвердили диагноз, остальные снимки ученые использовали в качестве контроля. Чтобы улучшить результативность будущего диагностического инструмента, они также оценивали клинические данные пациентов, включая лабораторные анализы, пол, возраст и симптомы.

Чувствительность нового ИИ ученые оценили в 84% по сравнению с 75% для врачей-рентгенологов, которые также анализировали снимки и клинические данные пациентов. В спорных ситуациях, когда на снимках не

было явных признаков болезни, ИИ правильно распознавал 68% случаев COVID-19. Врачи же исключили коронавирус во всех этих случаях.

Быстро обучить алгоритм искусственного интеллекта помогли миллионы людей, которые ежедневно делятся данными о своем состоянии в приложении COVID Symptom Study. Благодаря им ИИ с точностью почти 80% предсказывает вероятность инфицирования COVID-19 всего по четырем симптомам. На данный момент более 3,3 млн. человек во всем мире пользуются приложением COVID Symptom Study (ранее известное как Covid Symptom Tracker) для ежедневных отчетов о состоянии своего здоровья, независимо от их самочувствия. Его разработала группа ученых из Великобритании с целью мониторинга роста заболеваемости COVID-19 в конкретных районах и городах. Сегодня приложение используют в разных странах в надежде помочь ученым лучше понять симптомы и этапы развития COVID-19. При скачивании приложения каждый человек указывает свой пол, возраст, а также некоторые медицинские данные, включая хронические заболевания.

Чтобы обучить алгоритм искусственного интеллекта, ученые проанализировали данные около 2,5 млн. человек из Великобритании и США, которые регулярно отчитывались о своем самочувствии в приложении. Из них около трети участников регистрировали схожие с COVID-19 симптомы. Всего участники выполнили 18374 теста, из которых 7178 тысяч были положительными. Пользуясь этой уникальной базой данных, ученые проследили симптомы, которые чаще всего возникали у заболевших. Затем команда разработала математическую модель, которая почти с 80% точностью предсказывала вероятность COVID-19, исходя из пола, возраста и четырех основных симптомов: потери обоняния или вкуса, постоянного кашля, усталости, а также периодической потери аппетита. Когда команда применила эту модель к группе из 800 тысяч пользователей со схожими симптомами, то оказалось, что в то время (эксперимент проводился с 24 марта по 21 апреля) около 17,4% людей могли быть инфицированными. Применение этого инструмента поможет быстрее и эффективнее определять заболевших людей на самой ранней стадии COVID-19 и снизить дальнейшие риски инфицирования среди ближайшего окружения человека, уверены ученые. Они также надеются, что их данные будут убедительны для правительств многих стран, которые еще не включили симптом потери вкуса и обоняния к списку главных признаков COVID-19.

Группа китайских исследователей совместно с компанией Tencent AI Lab решила помочь решить задачу предвидения внезапного перехода течения болезни у зараженных COVID-19 в стадию осложнения. Исследования показали, что 6,5% пациентов с COVID-19 могут внезапно перейти к серьезной стадии заболевания, и уровень смертности среди них может достигать 49%. Поэтому одной из ключевых задач для органов здравоохранения является выявление и лечение пациентов, у которых на ранних стадиях могут развиваться тяжелые или смертельные синдромы.

Команда китайских ученых представила модель глубокого обучения, которая может предсказать риск развития критических заболеваний у пациентов с коронавирусом. Лаборатория разработала модель на основе когорты из 1590 пациентов из 575 медицинских центров в Китае, с последующей проверкой у 1393 пациентов. Совместная лаборатория сделала предиктор доступным онлайн, что позволило клиническому персоналу по всему миру рассчитать вероятность развития критического заболевания у пациентов в течение 5, 10 и 30 дней, используя десять клинических переменных.

В то время как основное внимание проекта сосредоточено на COVID-19, долгосрочная миссия лаборатории заключается в том, чтобы «использовать большие данные и ИИ для скрининга, профилактики и контроля, а также предупреждения о вспышках, респираторных заболеваниях и заболеваниях органов грудной клетки».

Немецкая больница Саудовской Аравии, один из крупнейших поставщиков медицинских услуг в ОАЭ, автоматизирует свои комплексные бизнес-процессы с помощью программных ботов на базе AI, чтобы помочь улучшить обслуживание пациентов и сократить время ожидания пациентов во время COVID-19. Программные боты предоставляются Automation Anywhere и развертываются Advansys ESC.

Медицина + ИИ: достижения и успехи

ИИ ставит диагнозы по МРТ так же точно, как и врачи. Но в 4 раза быстрее. Эксперты-рентгенологи доказали, что искусственный интеллект может оценивать результаты МРТ, ставить диагнозы и рекомендовать лечение. При этом модель делает это так же хорошо, как и обычные врачи. При слепом сравнении специалисты не смогли отличить выводы ИИ от заключения врачей. Система работает в четыре раза быстрее, чем живой специалист, поэтому может сократить время ожидания и затраты на дополнительные обследования. Исследование показало, что существенных различий в оценках специалистов и ИИ не было. Они обнаружили одни и те же отклонения и патологию независимо от того, кто делал эти выводы. Все исследователи оценили выводы, полученные с помощью ИИ, как более качественные, чем традиционные. Пять из шести рентгенологов не смогли правильно определить, какие изображения обработаны с помощью ИИ. Инженеры отмечают, что между выводами ИИ и специалистов могут быть различия только в случае, если в исходных данных есть излишние данные или «шум». В этом случае верные выводы может сделать только радиолог, поэтому пока выводы модели проверяет живой специалист.

Команда FastMRI строила свою модель на основании того, что некоторые из собранных данных в МРТ избыточны и не нужны для выводов. Это значит, что хорошо обученная система машинного обучения может сама делать выводы о том, какие данные важны для дальнейшего заключения, а какие нет. После этого ученые тренировали модель на большом количестве данных, так как снимки МРТ очень упорядочены и предсказуемы.

Ученые из Сколтеха и Научного центра исследований и разработки иммунобиологических препаратов имени М.П.Чумакова решили узнать,

могут ли системы искусственного интеллекта, помогающие покупателям в выборе товара, порекомендовать новые соединения для лечения вирусных заболеваний. Исследователи установили, что широко используемые алгоритмы способны не только рекомендовать пользователям подходящую музыку или фильмы в интернет-магазинах, но и эффективно отбирать соединения, обладающие противовирусной активностью. «Несмотря на то, что математические алгоритмы, лежащие в основе рекомендательных систем, обладают универсальностью, требуется глубокое понимание предметной области: медицинской химии, биологии и машинного обучения, чтобы создать эффективную рекомендательную систему для отбора перспективных противовирусных соединений. Наша работа была начата задолго до эпидемии коронавируса, и мы надеемся, что результаты ее помогут научному сообществу в поиске новых молекул, подавляющих активность SARS-CoV-2», – говорит о своей работе первый автор статьи, аспирант Сколтеха Екатерина Соснина.

Ученые из MIT разработали набор алгоритмов, который самостоятельно анализирует рентгеновские снимки грудной клетки, диагностирует некоторые заболевания, включая коллапс легкого и кардиомегалию, а затем решает, достаточно у него информации для самостоятельной постановки окончательного диагноза или стоит пригласить для этого конкретного специалиста-человека. Проект был разработан в лаборатории искусственного интеллекта Массачусетского технологического института. Ученые не стали сразу тестировать систему на реальных экспертах, а разработали серию «синтетических специалистов», чтобы настроить точные параметры и натренировать алгоритмы. Первичные результаты исследования показали, что искусственный интеллект на 8% чаще достигает успешных результатов в диагностике мегалии, по сравнению с экспертами-людьми. Однако, в MIT не собираются автоматизировать все медицинские задачи, а наоборот, работают над объединением человека и машины. Подобный подход к коллаборации кажется ученым наиболее эффективным. Сейчас ученые собираются протестировать обновленную версию системы, которая работает сразу с несколькими экспертами. ИИ будет одновременно работать с опытными рентгенологами и разными группами пациентов.

MEDICINE AND ARTIFICIAL INTELLIGENCE

Figovsky Oleg

Israel Inventors Association, Haifa, Israel, figovsky@gmail.com

The article is devoted to the description of the development of COVID 19. The article talks about some of the achievements of artificial intelligence in the fight against the pandemic.

Key words: pandemic, artificial intelligence, medicine, application of artificial intelligence, projects.

МЕДИЦИНА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ГЛАЗАМИ ПЕРМСКИХ УЧЕНЫХ

Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, yasn@psu.ru

Прослеживается история развития искусственного интеллекта как науки, постоянно реагирующей на текущие проблемы, возникающие в медицинской практике. Обращается внимание на то, что практически все современные нейростевые системы медицинского назначения являются статическими, т.е. они не имеют оси времени, и поэтому могут ставить диагнозы заболеваний только в текущий момент времени. В результате, врачам приходится делать назначения курсов лечения, не проверяя на компьютерных моделях, к чему эти лечения могут привести в будущем. Таким образом, осознанно или неосознанно, врачам приходится экспериментировать на пациентах, что представляет собой этическую проблему. В настоящей статье показано, что эта многовековая этическая проблема может быть решена путем дальнейшего развития и применения современных методов искусственного интеллекта. Оптимальный подбор курсов профилактики и лечения можно производить путем виртуального прогнозного экспериментирования на динамических компьютерных моделях пациентов.

Ключевые слова: Искусственный интеллект, нейронная сеть, диагностика, прогнозирование, виртуальные компьютерные эксперименты, биоэтика.

Мало кто из врачей знает, что поводом возникновения научной области, именуемой «Искусственный интеллект», были медицинские проблемы, и что первой интеллектуальной системой была механическая система медицинской диагностики, созданная испанским ученым Раймундом Луллием (рисунок 1) в XIII веке. Это открытие (назовем его **Открытием №1**) легло в основу технологии экспертных систем, с помощью которой в 1970-х годах учеными Стэнфордского университета (США) была разработана знаменитая система медицинской диагностики MYCIN.





Рисунок 1. Основатель искусственного интеллекта Раймунд Луллий и элемент его интеллектуальной системы медицинской диагностики

Следующим великим открытием (назовем его **Открытие №2**), приходящимся на середину XX века, было изобретение американскими учеными Уорреном МакКаллоком и Уолтером Питтсем математического нейрона [1] и создание Фредериком Розенблаттом персептрона (рисунок 2) [2], способного распознавать буквы латинского алфавита.

Однако, попытки практического применения персептрона для создания системы распознавания противника: «Свой или Чужой» (этот проект был актуален в США в связи с Карибским кризисом 1962 года) был неудачным. Потерпели неудачу и попытки создания нейросетевой системы диагностики инфаркта миокарда на основе данных электрокардиограмм.




Рисунок 2. Фредерик Розенблатт и его персептрон, распознающий буквы алфавита

Причина неудач заключалась в отсутствии эффективного алгоритма обучения многослойных нейронных сетей. Такие алгоритмы были изобретены в 1973 году (**Открытие №3**) российским ученым Александром Галушкиным [3] (рисунок 3) и, независимо от него в 1974 году – американскими учеными Полом Вербосом [4].

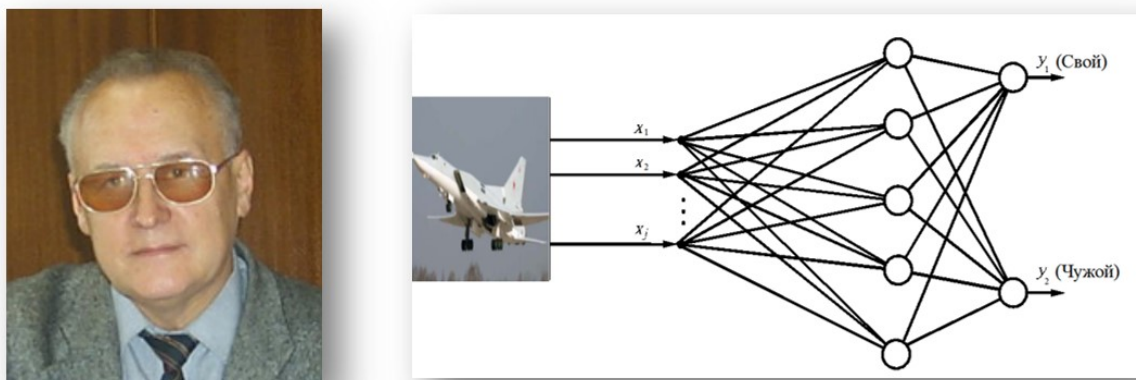


Рисунок 3. Александр Галушкин и многослойная нейронная сеть, обученная его методом

Открытия №2 и №3 ознаменовали появление новой технологии искусственного интеллекта – технологии нейронных сетей. Ее преимущество перед технологией экспертных систем состоит в том, что знания предметной области закладываются не автором компьютерной программы, а приобретаются в процессе обучения на практическом опыте (рисунок 4). Это свойство нейронных сетей оказалось особенно эффективно в медицине, теоретическая база которой далека от совершенства.

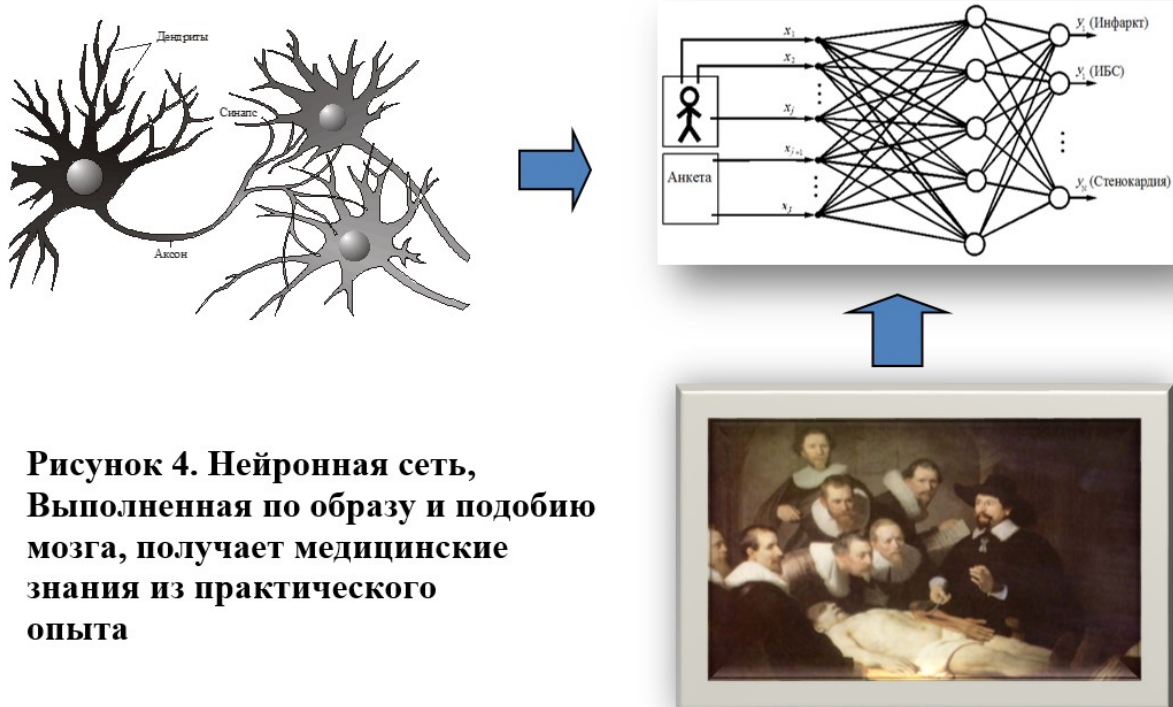


Рисунок 4. Нейронная сеть, выполненная по образу и подобию мозга, получает медицинские знания из практического опыта

В настоящее время для распознавания патологий на рентгеновских снимках большой популярностью пользуются сверточные нейронные сети. Эти сети обязаны своим появлением японскому ученому Кунихико Фукусиме [5], который в 1979 году изобрел способ более полного, по сравнению с персептроном, учета топологии распознаваемого объекта (**Открытие №4**).

В наши дни термин «Искусственный интеллект» стал необычайно популярен. В мировой медицинской литературе можно найти десятки сообщений об успешном применении нейронных сетей для диагностики самых различных заболеваний. Помимо термина «нейросетевая диагностика», встречаются сообщения, в которых упоминаются термины «прогноз заболеваний», «предсказание заболеваний», «оптимизация курсов лечения и профилактики».

Но!

При тщательном ознакомлении с текстами этих публикаций выясняется, что указанные термины используются только в узком смысле этого слова – как «исход заболевания», «выживет – не выживет», «какой процент пациентов выживет», «обратится ли пациент вновь к врачу», или как «диагноз, прогнозируемый в неопределенном будущем». А под «оптимизацией» иногда понимается оптимизация стоимости лечения. Сведений же о реальном применении аппарата нейронных сетей для моделирования заболеваний как процессов, развивающихся в организме человека во времени, тем более – для управления этими процессами, нам не удалось найти нигде.

Выражаясь математическим языком можно утверждать, что практически все нейростевые системы медицинского назначения во всем мире являются статическими. Они не имеют оси времени, и поэтому они могут ставить диагнозы заболеваний только в текущий момент времени.

В результате, врачи нередко назначают пациентам курсы лечения и наблюдают за пациентом: «поможет, или не поможет?». Если «не поможет», врачи назначают другие лекарственные препараты, и снова наблюдают.

Физики и инженеры такой метод работы называют экспериментированием «на натуральных объектах».

Но, «натурным объектом» в данном случае является живой человек!

Получается, что врачи, осознанно, или неосознанно, вынуждены экспериментировать на живых людях, что представляет серьезную этическую проблему. Дело в том, что эксперименты на живых людях без их согласия нарушают первый принцип Нюрнбергского кодекса [6] (рисунок 5).



Рисунок 5. Врач, назначающий курс лечения пациенту без предварительной проверки его действия на модели, нарушает первый пункт Нюрнбергского кодекса о запрете экспериментирования на людях

В отличие от врачей, представители технических дисциплин широко занимались экспериментированием «на натуральных объектах» только в прошлые века. В наше время инженеры, прежде чем принять какое-либо техническое решение, как правило, сначала создают компьютерную модель натурального объекта и выполняют над ней виртуальные компьютерные эксперименты. Путем виртуального компьютерного экспериментирования, они изучают, как поведет себя объект в тех или иных условиях, какие возникнут неисправности при его эксплуатации и какие меры надо предпринять, чтобы увеличить его ресурс.

Поэтому, с точки зрения физиков и инженеров, прямое экспериментирование на натуральных объектах – это анахронизм. Напрашивается вывод, что методологическая база медицинской науки отстала от технических дисциплин более чем на 100 лет!

Причины сложившейся ситуации вполне объяснимы. Дело в том, что сам объект моделирования – человек, по своей природе, несоизмеримо сложнее любого технического объекта, и методы классического моделирования (например, основанные на решении краевых задач математической физики), приемлемых для практического применения результатов не дают.

Здесь нужны принципиально новые подходы.

Одним из таких новых подходов, по-нашему мнению, являются подходы, основанные на развитии и применении методов искусственного интеллекта.

По-видимому, впервые возможности нейронных сетей для прогнозирования развития заболеваний во времени на количественном уровне, а также для подбора оптимальных курсов лечения и образа жизни пациентов, снижающих риски заболеваний, были показаны в публикациях **Пермских ученых** [7, 8]. На основе этих теоретических результатов (назовем их **Открытием № 5**) нами создан демонстрационный прототип интеллектуальной системы KARDIONET (www.KardioNet.ru), наглядно показывающий, что врачам, так же, как и инженерам, иногда можно

отказываться от натурального экспериментирования. Прежде, чем давать назначения пациентам, врачи могут создавать компьютерные модели пациентов и наблюдать на экране компьютера результаты действия лекарственных препаратов в течение будущих периодов времени. Экспериментируя на компьютерных моделях (рисунок 6), врачи, как и инженеры, могут подбирать наиболее оптимальные курсы лечения и профилактики заболеваний с учетом особенностей организма пациентов.



Рисунок 6. Прежде, чем давать назначения, врачи должны создавать компьютерные модели пациентов и, экспериментируя на них, подбирать оптимальные курсы профилактики и лечения пациентов

По мнению многих специалистов, развиваемый пермскими учеными подход может произвести настоящую революцию в медицинской науке и практике [8]. Он может открыть путь для перехода от все еще применяемого в медицинской практике «экспериментирования на пациентах» к экспериментированию на их компьютерных моделях и, таким образом, ликвидировать отставание медицинской науки от технических дисциплин. Таким образом, упомянутая выше этическая проблема современной медицины может быть решена.

У читателей может возникнуть естественный вопрос: Почему о возможностях динамического виртуального экспериментирования не заявляют авторы множества других аналогичных медицинских проектов? Ведь искусственный интеллект в наши дни стал чрезвычайно популярен и разработкой нейросетевых медицинских систем занимаются многие научные коллективы, имеющие большие финансовые и кадровые возможности.

Ответ на этот вопрос заключается в том, что пермские ученые – авторы KARDIONET начали заниматься проблемами искусственного интеллекта более 40 лет назад. За это время накоплен богатый опыт сотрудничества между врачами и математиками. Врачи и математики научились понимать друг друга и разговаривать на общем языке. Обнаружены и преодолены "подводные камни", препятствовавшие получению положительных

результатов. Разработаны методические приемы и Ноу-Хау, которыми современные молодые ученые пока еще не обладают [9].

Подводя итог изложенному, еще раз подчеркнем, что искусственный интеллект и медицина, как и прежде, продолжают находиться в тесной взаимосвязи между собой. Если искусственный интеллект, своим появлением на свет в XIII веке был обязан медицине, то в ближайшем будущем следует ожидать, что благодаря развитию и применению методов искусственного интеллекта, в частности – нейросетевых динамических систем [8], медицинская наука поднимется на качественно новый уровень. Будет решена многовековая этическая проблема: врачи больше не будут вынуждены прибегать к аморальному экспериментированию на пациентах. Оптимальный подбор курсов профилактики и лечения пациентов будет производиться путем виртуального прогнозного экспериментирования на динамических компьютерных моделях, учитывающих их индивидуальные особенности и состояние здоровья.

Благодарности. Исследования выполнены при финансовой поддержке гранта РФФИ 16-01-00164 «Гибридная нейро-экспертная система диагностики и прогнозирования развития сердечно-сосудистых заболеваний, позволяющая получать новые знания и полезные рекомендации».

Библиографический список

1. McCulloch W.S., Pitts W. A Logical Calculus of Ideas Immanent in Nervous Activity // Bull. Mathematical Biophysics. 1943. V.5.
2. Rosenblatt F. The perseptron: a probabilistic model for information storage and organization in the brain // Psychological Review. 1958. V.65.
3. Галушкин А.И. Об алгоритмах адаптации в многослойных системах распознавания образов // Доклады АН УССР (представлено акад. Глушковым В.М.). 1973. Т.91. № I, С. 15-21.
4. Werbos P.J. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences // Phd Thesis, Dept. of Applied Mathematics. Harvard University, Cambridge, MA., 1974.
5. Fukushima K. Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position — Neocognitron // Transactions of the IECSE, 1979, vol. J62-A(10). — P. 658–665.
6. Annas, George J., and Michael A. Grodin. The Nazi Doctors and the Nuremberg Code. New York, NY: Oxford University Press Inc., 1992. Print.
7. Yasnitsky L.N., Dumler A.A., Bogdanov K.V., Poleschuk A.N., Cherepanov F.M., Makurina T.V., Chugaynov S.V. Diagnosis and Prognosis of Cardiovascular Diseases on the Basis of Neural Networks // Biomedical Engineering. 2013. Vol. 47. No 3. Pp. 160-163. DOI: 10.1007/s10527-013-9359-0.
8. Yasnitsky L.N., Dumler A.A., Cherepanov F.M. (2019) Dynamic Artificial Neural Networks as Basis for Medicine Revolution. In: Antipova T., Rocha A. (eds) Digital Science. DSIC18 2018. Advances in Intelligent Systems and

Computing, vol 850, pp. 351-358. Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-02351-5_40.

9. Yasnitsky L.N. (2020) Whether Be New “Winter” of Artificial Intelligence?. In: Antipova T. (eds) Integrated Science in Digital Age. ICIS 2019. Lecture Notes in Networks and Systems, vol 78. Pp. 13-17. Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-22493-6_2.

MEDICINE AND ARTIFICIAL INTELLIGENCE THROUGH THE EYES OF PERM SCIENTISTS

Yasnitsky Leonid N.

Perm state University, 15, Bukireva str., Perm, Russia, 614990, yasn@psu.ru

The history of artificial intelligence as a science that constantly responds to current problems arising in medical practice is traced. Attention is drawn to the fact that virtually all modern neurological systems of medical use are static, i.e. they do not have a time axis, and therefore can diagnose diseases only at the current time. As a result, doctors have to make prescriptions of treatment courses without checking on computer models, which these treatments may lead to in the future. Thus, knowingly or unknowingly, doctors have to experiment on patients, which is an ethical problem. This article shows that this age-old ethical problem can be solved by further development and application of modern artificial intelligence methods. Optimal selection of preventive and treatment courses can be made by means of virtual predictive experiments on dynamic computer models of patients.

Keywords: Artificial Intelligence, neural network, diagnostics, prognostication, virtual computer experiments, bioethics.

СЕКЦИОННЫЕ ДОКЛАДЫ

КЛАССИФИКАЦИЯ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ОПРЕДЕЛЕНИЯ ТИПА ГРАЖДАНСКО-ПРАВОВОЙ ОТВЕТСТВЕННОСТИ

Алексеев Александр Олегович

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
alekseev@cems.pstu.ru

*Ерахтина Ольга Сергеевна, Кондратьева Ксения Сергеевна,
Никитин Тимур Фуркатович*

Национальный исследовательский университет «Высшая школа экономики»,
пермский филиал 614070, Россия, г. Пермь, ул. Студенческая, 38,
KSKondrateva@hse.ru

Подтвержден вывод о том, что нет единого подхода к решению вопроса о гражданско-правовой ответственности за действия искусственного интеллекта. Авторами предложено использование виновной ответственности, ответственности вне зависимости от вины и ответственности, основанной на риск-ориентированном подходе. Для целей определения типа ответственности за действие ИИ, предложена классификация технологий ИИ по четырем основаниям: работа в изменяющихся обстоятельствах окружающей среды; работа в условиях появления новых сигналах; число решаемых задач и выполняемых функций, фиксирование информации о деятельности технологии искусственного интеллекта. По мнению авторов, наиболее перспективным подходом к правовому регулированию ответственности за функционирование технологий искусственного интеллекта представляется риск-ориентированный подход. Представленные выводы свидетельствуют об актуальности темы исследования и начале формирования научного представления о гражданско-правовой ответственности за действия ИИ в России и за рубежом.

Ключевые слова: искусственный интеллект; разработчик технологий; классификация технологий, гражданско-правовая ответственность.

В последнее время с развитием информационных технологий, в частности технологий искусственного интеллекта (ИИ) и робототехники актуальной задачей становится совершенствование существующего гражданско-правового регулирования, о чем было сказано в Указе Президента РФ [1]. Междисциплинарный взгляд на данную проблематику

объясняется составом авторов, который включает юристов и специалиста в области компьютерной реализации технологий ИИ.

В современной отечественной правовой доктрине не существует единства относительно правовой природы ИИ: ряд исследователей вслед за европейской правовой мыслью [2] полагает, что необходимо сформировать особую концепцию электронного лица для искусственного интеллекта [2], другие, отождествляя ИИ и робота, полагают, что он может быть и объектом, и субъектом права [3], наконец, высказываются мысли о невозможности наделения искусственного интеллекта статусом субъекта права [4].

Из выводов последних исследований европейских ученых, отраженных, например, в Докладе экспертной группы «Ответственность за искусственный интеллект и другие развивающиеся электронные технологии» от 27.11.2019 года [5] следует, что невозможно создать единый режим ответственности для разных технологий в виду их разных свойств.

Вышесказанное свидетельствует о том, что в настоящее время с учетом отсутствия единых подходов относительно правовой природы ИИ, а также ответственности за его действия как на территории Российской Федерации, так и на территории Европейского союза поставленные Президентом РФ задачи по адаптации нормативного регулирования общественных отношений в сфере искусственного интеллекта являются актуальными и требующими своего разрешения.

В настоящей работе авторами предлагается ограничиться вопросом определения подхода к ответственности за действия ИИ. Для этого авторами предлагается технологии ИИ классифицировать по следующим основаниям:

1. Способность самостоятельно определять круг задач и без вмешательства человека находить пути их решения.

1.1. «Слабый» («пассивный»). Способен выполнять заранее определенные виды задач и ими же ограничен.

1.2. «Сильный» («активный»). Способен достичь или превысить уровень человеческого интеллекта и применять свои способности решения задач применительно к любым поставленным задачам, подобно человеческому мозгу.

2. Способность осуществлять функционирование без вмешательства человека:

2.1. Низкая автономность, способность осуществлять заданные программы и процедуры только по команде пользователя.

2.2. Высокая автономность, способность осуществлять заданные программы и процедуры без активного участия пользователя.

Стоит признать, что авторы довольно условно делят технологии искусственного интеллекта на две категории: с низкой и высокой автономностью, на практике выделяют большее число категорий, например в автомобилестроении SAE International выделили 6 уровней автономности [6].

3. Способность без непосредственного вмешательства человека овладевать новыми функциями.

3.1. Самообучаемый. Обладает возможностью без непосредственного вмешательства разработчика овладевать новыми навыками и способностями, в том числе извлекать знания и продукционные правила, а затем ими пользоваться на основе информации, не предусмотренной разработчиком при первичном обучении, или в процессе обновления ИИ.

3.2. Необучаемый. Не обладает возможностью без непосредственного вмешательства человека овладевать новыми навыками и способностями.

4. **Функциональность ИИ.**

4.1. Монофункциональный. ИИ применим для выполнения одной строго определенной функции.

4.2. Многофункциональный. ИИ применим для выполнения нескольких определенных функций.

5. **Оснащенность средствами объективного контроля.**

5.1. Оснащен программными и (или) аппаратными средствами объективного контроля, предназначенными для фиксации информации о функционировании ИИ.

5.2. Не оснащен ни программными, ни аппаратными средствами объективного контроля, предназначенными для фиксации информации о функционировании ИИ.

Сами технологии искусственного интеллекта и методы machine learning могут выступать шестым по счету, а не по значимости критерием для их классификации. К ним следует отнести, прежде всего, технологии нейросетевого моделирования; многоагентного моделирования, включая технологии роевого интеллекта, а также методы оптимизации, например, эволюционного и генетического поиска.

Безусловно, еще одним существенным критерием для классификации технологий ИИ является область применения: медицина, безопасность, энергетика, производство, развлечения и др. Однако, в настоящей работе область применения технологий ИИ авторами сознательно не рассматривается как одно из оснований для определения модели ответственности.

Важно отметить, что не все приведенные выше критерии, по которым можно классифицировать технологии ИИ, обладают свойством достаточности для определения модели гражданско-правовой ответственности разработчика за действие ИИ. Так, например, на текущий момент времени все известные технологии ИИ следует относить к пассивным технологиям, поэтому критерий «Активность» не может пока являться основанием для определения модели ответственности. В случае создания «сильного» или «активного» искусственного интеллекта, способного к самостоятельному целеполаганию, рефлексии и осознанию последствий осуществляемой им деятельности, актуальным встанет вопрос о признании такого ИИ самостоятельным субъектом права. Однако, как упоминалось выше, в докладе комиссии по законодательству Европарламента, а также других источниках [8–10], отмечается отсутствие целесообразности в данный момент признавать ИИ субъектом права.

Предлагается рассмотреть три базовых подхода к регулированию ответственности за действия ИИ: виновная ответственность; ответственность вне зависимости от вины и ответственность, основанную на риск-ориентированном правовом регулировании. В последнем случае ответственность возлагается на то лицо, которое должно было выполнить обязанность по минимизации рисков и не наступлению вредных последствий.

По мнению авторов, значимыми критериями для определения модели ответственности являются следующие: автономность, самообучаемость, функциональность и наличие средств объективного контроля.

Предлагаемые авторами подходы к регулированию гражданско-правовой ответственности за действия ИИ представлены в таблице ниже.

Таблица 1 – Зависимость гражданско-правовой ответственности разработчика от типа технологии ИИ

№ п/п	Основания критерии классификации технологий искусственного интеллекта	Подходы к регулированию гражданско-правовой ответственности за действия ИИ		
		Ответственность вне зависимости от вины (строгая ответственность)	Ответственность при наличии вины	Ответственность, основанная на риск-ориентированном правовом регулировании
1	Автономность	высоко автономный (1.1)	низко автономный (1.2)	
2	Самообучаемость	самообучаемый (2.1)	необучаемый (2.2.)	
3	Функциональность		монофункциональный (3.1)	многофункциональный (3.2)
4	Оснащенность средствами объективного контроля	не оснащен (4.1)	оснащен (4.2.)	

Как видно из таблицы выше, 4 существенных основания, каждое из которых дихотомически делится на наличие или отсутствие данного свойства

у технологии ИИ, порождает 16 ($16=2^4$) типов технологий, представляющих собой различные комбинации этих свойств (критериев).

Несмотря на то, что выделенные свойства технологий ИИ чаще (см. табл.) определяют строгую ответственность или ответственность при наличии вины, по мнению авторов, наиболее перспективным подходом к правовому регулированию ответственности за функционирование технологий ИИ представляется риск-ориентированный подход, например, за счет разработки отраслевых стандартов, саморегулирование и др. Этот вывод основан на том, что с развитием технологий ИИ, прогнозировать и контролировать его действия будет все сложнее, а в ряде случаев просто невозможно. Потребуется разработка стратегий управления рисками, связанными с применением сильного ИИ. Важная роль в решении этой задачи принадлежит институту гражданско-правовой ответственности.

Безусловно, с развитием научно-технического прогресса, будут появляться новые технологии ИИ, а соответственно и новые основания для их классификации. Важно отметить, что в целях определения типа гражданско-правовой ответственности, помимо критериев, приведенных в настоящей работе, необходимо использовать охраняемые законом блага (жизнь, здоровье, репутация и др.); сферы и области применения ИИ (медицина, безопасность, развлечение и др.), применяемые методы и технологии (искусственные нейронные сети, экспертные системы, мульти-агентные системы и др.); стороны (разработчик, интегратор, оператор-пользователь, обслуживающая организация) и др. Авторы не претендуют на полноту предлагаемой в настоящей работе классификации и осознают необходимость дальнейших исследований в данной области, чему будут посвящены будущие работы авторского коллектива.

Библиографический список

1. О развитии искусственного интеллекта в Российской Федерации: Указ Президента Российской Федерации от 10.10.2019 г. № 490 // Собрание законодательства Российской Федерации. 2019. № 41. ст. 5700
2. European Parliament resolution of 16 February 2017 with recommendations to the Commission on Civil Law Rules on Robotics (2015/2103(INL)). P. 17 [Электронный ресурс]: URL: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52017IP0051> (дата обращения 19.05.2020).
3. Морхат П.М. Правосубъектность искусственного интеллекта в сфере права интеллектуальной собственности: гражданско-правовые проблемы: дис. ... д-ра юр. наук. [Российская государственная академия интеллектуальной собственности]. – М., 2018.
4. Гришин Д.С. Проект Федерального закона «О внесении изменений в Гражданский кодекс Российской Федерации в части совершенствования правового регулирования отношений в области роботехники» [Электронный ресурс]. URL:

- <http://robopravo.ru/uploads/s/z/6/g/z6gj0wkwhv1o/file/bESvQz3Y.pdf> (дата обращения 19.05.2020).
5. Дурнева П.Н. Искусственный интеллект: анализ с точки зрения классической теории правосубъектности // Гражданское право. 2019. № 5. С. 30–33.
 6. Liability for Artificial Intelligence and Other Emerging Digital Technologies. [Электронный ресурс] URL: <https://op.europa.eu/en/publication-detail/-/publication/1c5e30be-1197-11ea-8c1f-01aa75ed71a1/language-en/format-PDF> (дата обращения 02.05.2020).
 7. Automated driving / SAE International. URL: https://www.sae.org/binaries/content/assets/cm/content/news/press-releases/pathway-to-autonomy/automated_driving.pdf (дата обращения: 01.09.2020).
 8. Draft Report with Recommendations to the Commission on Civil Law Rules on Robotics. 2015/2103 (INL) / European Parliament. Committee of Legal Affairs. URL: https://www.europarl.europa.eu/doceo/document/JURI-PR-582443_EN.pdf?redirect (дата обращения: 01.09.2020).
 9. White Paper On Artificial Intelligence COM(2020) 65 final A European approach to excellence and trust [Электронный ресурс]: URL: https://ec.europa.eu/info/sites/info/files/commission-white-paper-artificial-intelligence-feb2020_en.pdf (дата обращения 24.05.2020).
 10. Raaijmakers S. Artificial Intelligence for Law Enforcement: Challenges and Opportunities // IEEE Security & Privacy. 2019. Vol. 17, Iss. 5. P. 74–77.

ARTIFICIAL INTELLIGENCE TECHNOLOGIES CLASSIFICATION FOR DETERMINATION OF THE CIVIL LIABILITY

Alekseev Alexander O.

Perm National Research Polytechnic University, Komsomolsky Av. 29, Perm,
Russia, 614000, alekseev@cems.pstu.ru

Erakhtina Olga S., Kondratyeva Ksenia S., Nikitin Timur Ph.

National Research University Higher School of Economics – Perm, 27, Lebedeva
st., Perm, 614017, Russia, KSKondrateva@hse.ru

The conclusion is confirmed that there is no unified approach to solving the issue of civil liability for the actions of artificial intelligence. The authors proposed the use of guilty liability, liability regardless of guilt and liability, based on a risk-oriented approach. For the purpose of determining the type of liability for the action of AI, the classification of AI technologies is proposed on four grounds: work in changing environmental conditions; work in conditions of the appearance of new points; the number of tasks to be solved and functions performed, recording information about the activities of artificial intelligence technology. According to the authors, the most promising approach to the legal regulation of liability for the functioning of artificial intelligence technologies is a risk-oriented approach. The

presented conclusions testify to the relevance of the research topic and the beginning of the formation of a scientific understanding of civil liability for the actions of AI in Russia and abroad

Keyword: artificial intelligence, technology developer, technologies classification, civil liability

УДК 336.572/.576

НЕЙРОСЕТЕВАЯ МОДЕЛЬ В ПОДХОДАХ К ВЫБОРУ РАСПРЕДЕЛЕНИЯ ФИНАНСОВЫХ СРЕДСТВ МУНИЦИПАЛЬНЫМ УЧРЕЖДЕНИЯМ

Бирюков Александр Николаевич

Стерлитамакский филиал Башкирского государственного университета
453103, Россия, Республика Башкортостан, г. Стерлитамак,
проспект Ленина, 49

Данная работа посвящена проблемным вопросам совершенствования краткосрочного планирования расходной части бюджета муниципальных образований через экономико-математическую концепцию с применением нейросетевой модели.

Ключевые слова: нейросетевая модель, муниципальные учреждения, метод агрегирования, байесовский ансамбль.

В работе [1] с позиции общесистемных законов кибернетики разработана прогнозная нелинейная многофакторная, нейросетевая модель, которая включает в себя:

1) нейросетевую модель аппроксимации и прогноза, обобщенного показателя эффективности Φ работы муниципального учреждения (МУ), зависящего от ряда производственных показателей $\{X_j\}$; 2) модель агрегирования переменных; 3) модель оптимизации распределения субвенций либо трансфертов между МУ.

Изложение проводится конкретно на примерах МУ общеобразовательного типа, но разработанный методологический подход справедлив практически для любых МУ. Указанная *гибридная нейросетевая модель (ГНСМ)* реализует экономико-математическую концепцию на рис. 1, замыкая методику распределения фонда материального развития (ФМР) субвенций.

Ядро ГНСМ – это нейросетевая динамическая модель восстановления зависимости $\Phi(X_j)$, скрытой в данных, которая получается с помощью метода вложенных математических моделей. При построении модели $\Phi(X_j)$ проблемным моментом прикладного характера было агрегирование

эндогенных и экзогенных переменных в силу их слабой обозримости. Был проведен анализ известных методов агрегирования показателей. На основе морфологического подхода и диаграммы Исикава предложен оригинальный метод агрегирования, в котором по осям «морфологического ящика» располагаются частные критерии эффективности деятельности, представляющие собой агрегаты – линейные весовые свертки $\{\Phi_{k,r}\}$ из производственных показателей $\{X_j\}$, где k – номер агрегата, r – номер показателя (фактора). Обобщенный критерий оценки эффективности конструируется в виде мультипликативной свертке частных критериев:

$$\Phi = \prod_{k=1}^m \Phi_{k,r} (X_j); \quad (1)$$

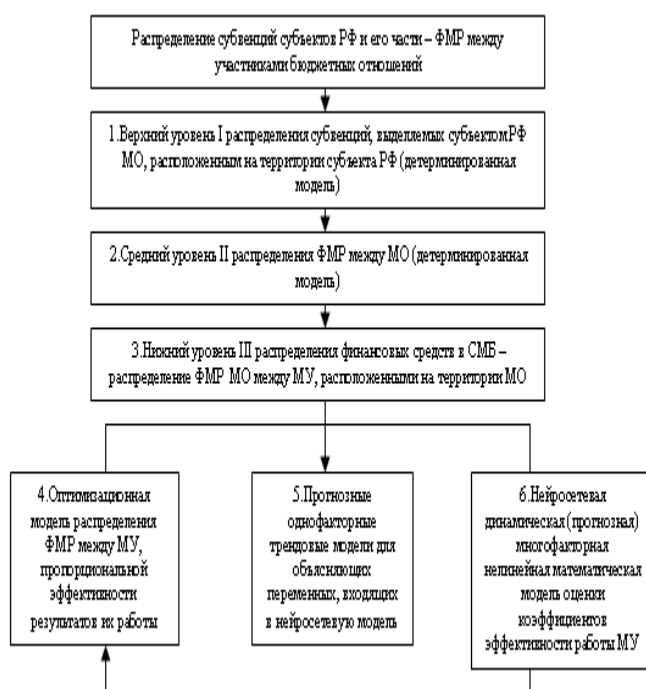


Рисунок 1. Структурно-функциональная схема 3^X – уровневой системы распределения финансовых средств муниципального образования

Экзогенные переменные тоже подвергаются агрегированию в виде линейных весовых свертки. Весовые коэффициенты в линейных свертках определялись экспертно. Частные критерии $\{\Phi_k (X_j)\}$ должны быть однонаправленными, что позволяет образовывать из них вариационные ряды для поддержки принятия управленческих решений.

Преимуществами разработанного метода агрегирования согласно (1) является:

- Хорошая интерпретируемость результатов моделирования: улучшению эффективности работы анализируемого МУ соответствует уменьшению (либо увеличение в зависимости от контекстного смысла частных критериев $\{\Phi_k (X_j)\}$) обобщенного критерия $\Phi(\Phi_k (X_j))$, а,

следовательно, возможность оптимизации разработки управленческого решения.

- Возможность выявления направлений рационального развития МУ путем вычисления функций чувствительности частных критериев от вариации показателей: $\varphi(X_j) = \partial \Phi_k(X_j) / \partial X_j$.

- Взаимосвязь («сцепление») показателей $\{X_j\}$ с обобщенным критерием Φ в (1) (рис.1) существенно возрастает за счет операции умножения в мультипликативной свертке, т.е. индексы корреляции $\{|r_{\Phi, \Phi_k}|\}$ существенно выше, чем $\{|r_{\Phi_k, X_j}|\}$. При возрастании связи моделируемого обобщенного критерия Φ с аргументами Φ_k улучшается качество обучения нейросети [2].

Пример ранжирования общеобразовательных учреждений [3]. Целью построения НСМ в этом примере было многофакторное и многокритериальное ранжирование средних школ с целью реализации принципа бюджетирования, ориентированного на конечный результат и замыкания схемы рис. 1. Рассмотрено 9 МУ: 2 школы-лицея, 2 школы-интерната и 5 средних школ. В этой задаче главная трудность состояла в спецификации переменных. При спецификации использовался метод экспертных оценок с дообучением экспертов, т.е. итерационное уточнение спецификации с анализом промежуточных вычислительных экспериментов. Этот метод позволяет в некоторой мере упорядочить (частично формализовать) внесение в модель априорной информации о моделируемом объекте. Достижимый эффект от процедуры дообучения экспертов – обострение их интуиции, отображаемой в назначении весовых множителей при образовании агрегированных переменных в формулах, а также в выборе состава переменных.

По мнению экспертов, выходная характеристика качества работы общеобразовательных учреждений определяется в основном двумя факторами учебного процесса: 1) уровнем квалификации преподавательского состава; 2) качеством подготовки выпускников школ в аспекте дальнейшего повышения уровня образования, а также эффективной работы в различных сферах человеческой деятельности.

Соответственно выбран агрегат-конфигуратор вида (1), где Φ_1 – линейная свертка показателей, характеризующих квалификацию преподавательского состава; Φ_2 – линейная свертка качества знаний, полученных учащимися. Поскольку нас интересует ранжирование школ по эффективности работы в будущем, т.е. на планируемый период, то нейросетевая многофакторная модель должна быть динамической. Поэтому использованы данные панельного типа. Соответственно, в качестве фактора X_1 принято относительное время. Для учета структуры моделируемых объектов введено две булевых переменных: $X_2 = 1$, если объект – лицей (гимназия) и $X_2 = 0$ в противном случае; $X_3 = 1$, если объект – школа интернат и $X_3 = 0$ в противном случае. Безусловно, фонд оплаты труда (ФОТ)

и начисления на оплату труда учителей напрямую связаны с квалификацией учителей (агрегатом Φ_1) и косвенно с агрегатом Φ_2 , характеризующим качество знаний. Поэтому выбран фактор X_4 – относительное значение ФОТ и начислений на ФОТ, приходящийся на одного работника в течение квартала, тыс. руб./человека. Уровень материального обеспечения учебного процесса характеризуется двумя факторам: X_5 – расход средств на одного ученика в течение года, тыс. руб./человека; X_6 – общая сумма расходов данного образовательного учреждения за квартал, тыс. руб.

Нейросетевая модель содержала для регуляризации, байесовский ансамбль из 6 сетей типа MLP с алгоритмом обучения Back Propagation, различающихся активационными функциями, числом скрытых слоев, оптимальным числом нейронов в этих слоях [2]. Данные были подвергнуты предобработке (рис. 2), т.е. очистке от аномальных точек по мультипликативному критерию, где $NMSE$ – нормированная на размах $(Y_{max} - Y_{min})$ среднеквадратичная ошибка сети, а также по аддитивному критерию $J_1 = C_1E + C_2(NMSE)$.




Рисунок 2. Результаты оптимальной очистки БД 1– минимизация по критерию J_1 ; 2 – по критерию J_2

Нейросети ансамбля хорошо подтверждают друг друга в ансамбле, что видно на рис. 3, который построен для объекта: (школы-лицеи). Видно, что кривые образуют плотный пучок.




Рисунок 3. Нейросетевой ансамбль – прогноз Φ для объекта: (школы-лицеи)

Это иллюстрирует об адекватности прогнозной многофакторной НСМ. Изломы на кривых объясняются тем, что в каждый последующий интервал времени изменяются входные факторы, $X_1, X_4(\bar{t}), X_5(\bar{t}), X_6(\bar{t})$, которые при подстановке в НСМ приводят к изломам на кривой $\Phi(\bar{X}(\bar{t}), \bar{t})$.

Итоги ранжирования на планируемый период (3 месяца следующего года):

- объект 1 – $\Phi = 0,0245$;
- объект 2 – $\Phi = 0,0246$;
- объект 3 – $\Phi = 0,0231$;
- объект 4 – $\Phi = 0,0225$;
- объект 5 – $\Phi = 0,0224$;
- объект 6 – $\Phi = 0,0228$;
- объект 7 – $\Phi = 0,0233$;
- объект 8 – $\Phi = 0,0136$;
- объект 9 – $\Phi = 0,0138$.

Максимальная эффективность работы МУ соответствует $\Phi = 0,246$.

Библиографический список

1. Бирюков А.Н. Байесовская регуляризация нейросетевых моделей ранжирования и кластеризации экономических объектов. // – Уфа: Академия наук РБ, Издательство «Гилем» – 2011. – 292 с.
2. Горбатков С.А., Полупанов Д.В., Бирюков А.Н., Макеева Е.Ю. Методологические основы разработки нейросетевых моделей экономических объектов в условиях неопределенности. // М.: Издательский дом «Экономическая газета». – 2012. – 494с.
3. Бирюков А.Н., Глуценко О.И. Корректная постановка обратных задач восстановления многомерных функций через нейросетевые модели в бюджетном администрировании // Вестник Уральского

государственного федерального университета, серия «Экономика и управление» – 2017. –Т. 16. – № 2. – С. 227-245

4. Biryukov A. N., Antonova N. A. Expert systems of real time as key tendency of artificial intelligence in tax administration. // The 2018 International Conference on Digital Science – DSIC'18. Budva Convention Centre, Montenegro. DSIC18 2018: Digital Science pp 111-118 | Cite as
5. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

NEURAL NETWORK MODEL IN APPROACHES TO CHOOSING THE DISTRIBUTION OF FINANCIAL RESOURCES TO MUNICIPAL INSTITUTIONS

Biryukov Alexander Nikolaevich

Sterlitamak branch of Bashkir state University 49 Lenin Avenue,
Sterlitamak, Republic of Bashkortostan, Russia, 453103

This work is devoted to the problematic issues of improving the short-term planning of the expenditure part of the budget of municipalities through an economic and mathematical concept using a neural network model.

Key words: neural network model, municipal institutions, aggregation method, Bayesian ensemble.

УДК 004.8; 519.6

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОБНАРУЖЕНИЯ ФАКТОВ КУРЕНИЯ В СИСТЕМАХ ВИДЕОНАБЛЮДЕНИЯ

Гладкий Сергей Леонидович

ООО «ВИПАКС», 614000, Россия, г. Пермь, ул. Краснова, 24,
lrndlrnd@mail.ru

Данильченко Павел Владимирович, Романов Никита Сергеевич

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
pavel.danilchenko96@gmail.com

В статье описано применение свёрточных нейронных сетей и каскадных классификаторов для отслеживания фактов курения применительно к системам видеонаблюдения. Предложены 2 способа обнаружения курения. Первый способ подразумевает обнаружения сигареты на фоне человеческого лица. Второй способ предполагает обнаружение кисти руки с сигаретой в ней. На основе предложенных способов разрабатывается программное

обеспечение для системы видеонаблюдения, позволяющее в режиме реального времени определять наличие фактов курения, и тем самым преждевременно предотвращать возможные нежелательные последствия.

Ключевые слова: компьютерное зрение, глубокое обучение, свёрточная нейронная сеть, каскадный классификатор, видеонаблюдение, система безопасности, курение, сигарета.

Одним из наиболее быстро растущих направлений разработки программного обеспечения является область компьютерного зрения, а стремительное развитие существующего аппаратного обеспечения лишь подстёгивает создание всё более сложных методов анализа изображений [1, 2]. Методы компьютерного зрения нашли широкое применение в современных системах видеонаблюдения [3-5]. Они используются для классификации и определения положения объектов, слежения за их перемещением, обнаружения пересечения границ, детектирования и идентификации лиц, поиск и распознавание автомобильных номеров или некоторых меток и т.п. При решении подобных задач в настоящий момент обычно используют нейронные сети глубокого обучения и свёрточные нейросети в частности [6-8]. Кроме того, компьютерное зрение может применяться для повышения безопасности жилых зданий, торговых центров, складских помещений, промышленных предприятий и т.п. за счёт осуществления обнаружения возможного возгорания или задымления по видеоизображению [9]. Обычно, своевременная локализация и устранение возгорания при раннем его обнаружении может обойтись малыми потерями в материальном и финансовом выражении, без жертв и пострадавших, однако существуют ситуации, когда лишь наличие самого источника возможного возгорания, будь то искры или тлеющей сигареты, несёт угрозу самому существованию объекта и жизням находящихся там людей. Например, искра от тлеющей сигареты на складе с взрывоопасными удобрениями, на предприятии по сжижению природного газа или на нефте- и газодобывающих предприятиях может привести к мощному взрыву, гибели людей, разрушению как самого предприятия, так и находящейся рядом инфраструктуры и зданий.

Известны факты, когда сотрудники, несмотря на риск, всё же решаются закурить на территории объекта. Иногда такие случаи попадают в поле зрения видеокамер, но остаются незамеченными. Ввиду неэффективности датчиков дыма и иных существующих решений на открытом пространстве и в продуваемых зонах существует потребность в автоматическом обнаружении фактов курения на видеопотоке. Это поможет свести к минимуму число подобных случаев и привлечь к ответственности нарушающих технику безопасности. Кроме того, сам факт наличия такого детектора в составе системы видеонаблюдения будет дополнительно мотивировать сотрудников к соблюдению техники безопасности.

Существующие решения на основе одной нейросети, обнаруживающие факты курения, обладают очень низкой точностью и низкой скоростью

срабатывания [10]. Обнаружить факт курения можно как по наличию сигареты, так и по выдыхаемому дыму, однако во втором случае, при некоторых условиях окружающей среды, например, при низких температурах, за дым можно принять выдыхаемый влажный воздух, поэтому детектирование выдыхаемого дыма не рассматривается. Таким образом, заметить факт курения можно лишь при поиске сигареты в кадре. Для решения данной задачи было решено разделить её на две: поиск лиц с сигаретой во рту и поиск кистей рук, держащих сигарету. Поиск лиц с сигаретами реализован в 2 этапа: сначала каскадный классификатор находит лица на изображении, а потом найденные части изображения с лицами классифицируются нейронной сетью.

Для локализации лиц на изображениях было решено использовать каскадные классификаторы, т.к. они являются относительно легковесными и быстрыми, по сравнению даже с простыми свёрточными нейронными сетями, которые можно было бы использовать с той же целью. Разработка интеллектуальной системы видеонаблюдения ведётся с использованием свободно распространяемой библиотеки компьютерного зрения OpenCV, поэтому на принятие данного решения в значительной степени повлияло наличие свободно распространяемых каскадных классификаторов для обнаружения лиц в профиль и анфас, которые могут быть запущены с помощью OpenCV. Кроме того, данные каскадные классификаторы облегчают формирование обучающей выборки.

После локализации лица каскадным классификатором части изображений, на которых содержатся лица, передаются на вход свёрточной нейронной сети для определения их принадлежности к одному из трёх классов: ложное срабатывание каскадного классификатора, лицо без сигареты и лицо с сигаретой. Значительное отличие лиц в профиль и анфас подразумевает наличие не только двух каскадных классификаторов, но и двух различных нейронных сетей, которые должны обучаться на соответствующих обучающих выборках, как на рисунках 1 и 2. Для данных сетей были опробованы несколько вариантов структур, и для каждой из сетей были выбраны те, которые показали наилучшие результаты при обучении. Так, например, на рис. 3 представлена структура нейросети для лиц в профиль.




Рисунок. 1 Примеры размеченных изображений обучающей выборки, для обнаружения сигареты во рту в профиль: а) изображения от ложного срабатывания каскадного классификатора, б) лицо в профиль, в) лицо в профиль с сигаретой




Рисунок. 2 Примеры размеченных изображений обучающей выборки, для обнаружения сигареты во рту анфас: а) изображения от ложного срабатывания каскадного классификатора, б) лицо анфас, в) лицо анфас с сигаретой

Обучение нейронных сетей производилось с помощью Caffe. Обучающая и тестовая выборки для лиц в профиль включали в себя 6000 и 600 изображений соответственно, а для лиц анфас 5000 и 1000 изображений. В результате обучения сетей была достигнута точность классификации 90% для лиц в профиль на тестовой выборке. Нейронная сеть иногда некорректно определяла класс с ложным срабатыванием каскадного классификатора. Для устранения этой проблемы было принято добавить в обучающую выборку максимально схожие изображения, которые определялись неверно. В конечном итоге удалось повысить точность нейронной сети до 92% и снизить количество ложных срабатываний сети при ложном срабатывании каскадного классификатора в 5 раз. Точность классификации лиц анфас составила 92,5%.

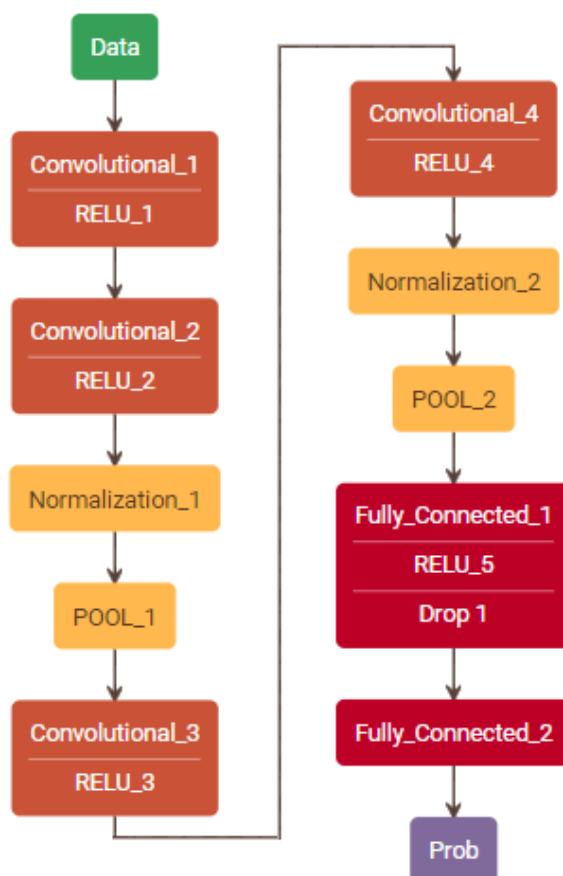


Рис. 3 Структура свёрточной нейронной сети, используемой в классификации изображений с лицами в профиль

Курящие не постоянно держат сигарету во рту, значительную часть времени они держат сигарету в руках, поэтому для повышения вероятности обнаружения фактов курения имеет смысл реализовать детектор сигарет в руках. Однако, обнаружение сигареты в руке является более сложной задачей. Это объясняется тем, что лица обычно видны в правильном, вертикальном положении, и достаточно лишь двух уже существующих классификаторов, но кисть, в отличие от головы, несимметрична, может наблюдаться с разных сторон и под разными углами, при этом держать сигарету в руке можно несколькими способами. Существующие решения для обнаружения кистей и распознавания жестов не подходят для данной задачи в виду избыточной сложности, а создание отдельного каскадного классификатора на каждый случай не является приемлемым решением, поэтому возникает необходимость создания нейросети, которая позволяла бы локализовать кисти. Также возникает вопрос о целесообразности разделения нейросетей для локализации кистей и определения наличия сигареты, либо совмещении их в одной. Решение данной задачи будет прорабатываться в дальнейшем.

Таким образом предложен новый подход, позволяющий обнаруживать факты курения и обучены 2 свёрточных нейросети с точностью более 90%. Предложенные алгоритмы реализуются в детекторе курения интеллектуальной системы видеонаблюдения DOMINATION компании

ВИПАКС, а обнаружение лиц с сигаретами уже внедрено в систему и работает на тестовом сервере.

Библиографический список

1. Шапиро Л., Стокман Дж. Компьютерное зрение.: Пер. с англ. – 2-е изд. (эл.) – Москва: БИНОМ. Лаборатория знаний, 2013, 752 с.
2. Лукьяница А.А., Шишкин А.Г. Цифровая обработка видеоизображений. М.: «Ай-Эс-Эс Пресс», 2009. – 518с.
3. Rosebrock A. Deep Learning for Computer Vision with Python. Starter Bundle. – pyimagesearch.com, 2017. – 332 p.
4. Rosebrock A. Deep Learning for Computer Vision with Python. Practitioner Bundle. – pyimagesearch.com, 2017. – 210 p.
5. Rosebrock A. Deep Learning for Computer Vision with Python. ImageNet Bundle. – pyimagesearch.com, 2017. – 323 p.
6. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. – 2-е изд., испр. – М.: ДМК Пресс, 2018. – 652 с.: цв. ил.
7. Chollet F. Deep Learning with Python. – NY.: Manning Publications Co., 2018. – 386 p.
8. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – СПб.: Питер, 2018. – 480 с.: ил.
9. Гладкий С.Л. Опыт применения дифференциальных уравнений и нейронных сетей для распознавания физических явлений на видеоизображениях // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всерос. науч.-практ. конф. Пермь: Перм. гос. нац. исслед. ун-т. 2019. С. 36-43.
10. Комплекс детекции курения по фото или видео на базе Intel NUC [Электронный ресурс]. // Хабр. – URL: <https://habr.com/ru/company/intel/blog/493726/>

APPLICATION OF NEURAL NETWORKS FOR DETECTING THE FACTS OF SMOKING IN VIDEO SURVEILLANCE SYSTEMS

Gladkiy Sergey L.

LLC «VIPAKS», Krasnova st., 24, Perm, Russia, 614000, lrndlrnd@mail.ru

Danilchenko Pavel V., Romanov Nikita S.

Perm National Research Polytechnic University, Komsomolsky Av. 29, Perm, Russia, 614000, pavel.danilchenko96@gmail.com

The article describes the use of convolutional neural networks and cascade classifiers for tracking smoking facts in relation to video surveillance systems. Two methods of smoking detection are proposed. The first method involves detecting a cigarette against the background of a human face. The second method involves detecting a hand with a cigarette in it. On the basis of the proposed

methods, software for a video surveillance system is being developed, which makes it possible to determine the presence of the facts of smoking in real time, and thereby prematurely prevent possible undesirable consequences.

Key words: computer vision, deep learning, convolutional neural network, cascade classifier, video surveillance systems, smoking, cigarette.

УДК 004.8

ПЕРЕНОСИМОЕ ОБУЧЕНИЕ НА ОСНОВЕ ЗНАНИЙ В КОМПЬЮТЕРНОМ ЗРЕНИИ

Гладкий Сергей Леонидович

ООО «ВИПАКС+», 614000, Россия, г. Пермь, ул. Краснова, 24,
lrndlrnd@mail.ru

В статье рассмотрены несколько проблем в области переносимого обучения в компьютерном зрении. Одним из методов переносимого обучения является использование предварительно обученных сверточных сетей для извлечения признаков объектов. При этом возникает проблема несоответствия данных, используемых при обучении и распознавании объекта. Второй проблемой является избыточность признаков в предварительно обученной сверточной сети. Наконец, сами признаки, извлекаемые для распознавания объектов, не всегда являются оптимальными. Предложены новые методы реализации переносимого обучения, направленные на решение озвученных проблем. Методы основаны на специальном обучении сверточной сети, позволяющем контролировать обучаемые признаки, и, таким образом, закладывать в нейронную сеть некоторые знания. Так же изложены идеи, основанные на знаниях о зрительной системе, которые могут быть использованы для создания нейронных сетей с новой архитектурой.

Ключевые слова: искусственный интеллект, сверточная нейронная сеть, глубокое обучение, переносимое обучение, компьютерное зрение.

Наиболее успешно в области компьютерного зрения используются нейронные сети глубокого обучения, или сверточные сети [1, 2]. Они применяются, например, для распознавания класса объектов и определения их местоположения, идентификации личности человека по лицу, распознавания автомобильных номеров. Одной из технологий применения сверточных нейронных сетей является переносимое обучение [3-5]. Суть переносимого обучения в следующем: предварительно обучается сверточная нейронная сеть на некотором наборе данных, которая потом может использоваться как основа для получения признаков и обучения нескольких специализированных нейронных сетей.

Выделяют два основных метода использования переносимого обучения: выделение признаков (feature extraction) и тонкая настройка (fine tuning). При выделении признаков, из предварительно обученной сверточной сети ‘вырезается’ часть, содержащая все слои, вплоть до последних полносвязных слоев (персептрона) (рис. 1 а). Эта обученная часть используется как базовая нейронная сеть для получения признаков. К ней добавляется новая часть, состоящая, как правило, также из полносвязных слоев, и представляющая собой обычный персептрон (рис. 1 б). Полученная новая нейронная сеть обучается на новых данных, для решения некоторой специализированной задачи. При обучении, базовая часть (предобученные сверточные слои) замораживается – то есть не участвует в процессе обучения. Таким образом, признаки, обученные в базовой сверточной сети, используются в новой нейронной сети, но уже для решения другой, специализированной задачи. Метод тонкой настройки аналогичен первому методу. Однако, при обучении новой нейронной сети, часть сверточных слоев базовой части ‘размораживается’, то есть участвует в процессе обучения на новых данных (рис. 1 в). Таким образом, происходит ‘настройка’ этих слоев на новые данные, что, обычно, приводит к получению большей точности решения задачи.

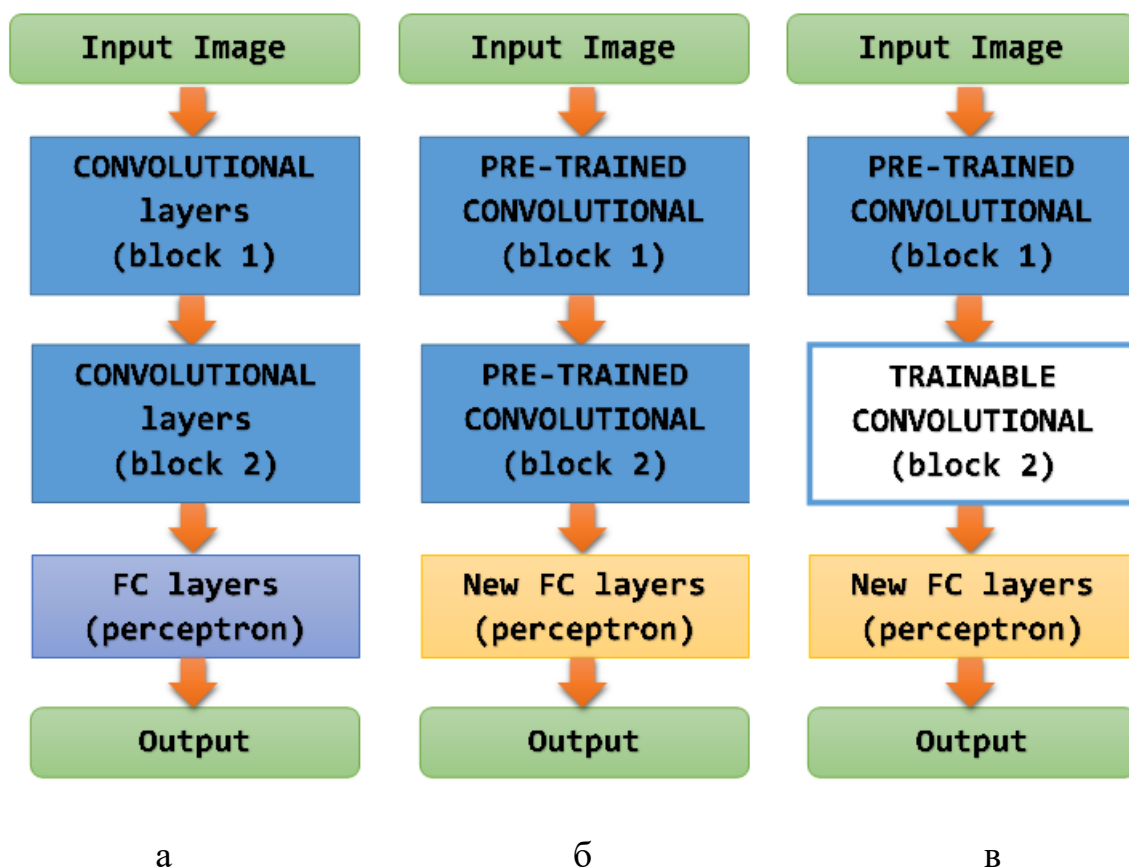


Рисунок 1. Схема использования переносимого обучения: а) базовая модель б) выделение признаков в) тонкая настройка

Несмотря на большой успех использования переносимого обучения для решения множества задач компьютерного зрения, подход, используемый сейчас, обладает множеством недостатков. Во-первых, предварительно обученная нейронная сеть, используемая как база для извлечения признаков, должна быть обучена на наборе данных, который соответствует данным, на которых обучается конечная нейронная сеть, в том смысле, что данные содержат те же признаки. Если сверточная нейронная сеть обучена, например, на объектах и сценах внутри помещений, она не может быть использована как база для извлечения признаков объектов, находящихся на улице, сценах природы и так далее. Очевидно, что данная нейронная сеть просто не будет способна найти необходимые признаки. Частично, данная проблема решается использованием тонкой настройки, однако полностью она решена быть не может, поскольку в пределе исчезает сама идея переносимого обучения.

Так же, первую проблему несоответствия данных обычно решают тем, что базовая сверточная сеть обучена на огромном наборе данных, типа ImageNet, включающем объекты, для которых будет использована специализированная нейронная сеть. Это создает вторую проблему – базовая нейронная сеть получается чрезвычайно ‘тяжелой’ и избыточной. Она будет выделять признаки, большинство из которых не будет использовано для принятия конечного решения. Такая сеть будет требовать слишком много ресурсов, как памяти, так и вычислительных. Для решения же специализированной задачи, обычно, требуется более ‘легкая’ и ‘быстрая’ сеть.

Третья проблема переносимого обучения связана с признаками, которые способна выделять сверточная нейронная сеть. Эти признаки формируются в процессе обучения базовой сверточной сети на большом наборе данных. Какие именно признаки будет способна выделить сеть зависит как от данных, так и от архитектуры и метода обучения. В общем случае, для современных архитектур, эти признаки никак не контролируются. В [6] приводятся примеры признаков, извлеченных из сверточной сети. Здесь можно видеть и избыточность признаков, и их хаотичность. Кроме того, например, выделен признак ‘яркая зеленая точка’, который, как можно предположить, может быть использован, как один из признаков для детекции кошки. Можно так же предположить, что сеть может выделять яркие точки другого цвета, как признаки для детекции объектов других классов. Однако, более эффективным способом было бы иметь признак ‘яркая точка’ и признак цвета, которые могли бы быть объединены уже на этапе принятия решения. Это позволило бы уменьшить количество ядер сверточных слоев, а значит, повысить производительность нейронной сети. Есть основания полагать, что подобным образом работает зрительная система человека, и это позволяет ей быть настолько эффективной в распознавании образов [7].

В настоящей работе предлагаются подходы к разработке новых архитектур сверточных нейронных сетей и их обучению, которые позволят в

перспективе решить изложенные выше проблемы и сделать переносимое обучение более эффективным. Все предлагаемые подходы основаны на знаниях о работе зрительной системы человека. Следует отметить, что даже к настоящему моменту функционирование зрительной системы изучено на достаточно поверхностном уровне. Однако, известно, что она состоит из нескольких зрительных зон, обозначаемых обычно V_1, V_2, \dots, V_7 . Каждая зона отвечает за обработку и распознавание определенного типа информации: локальные признаки – грани, углы, линии; геометрические фигуры; цвета и текстуры; сложные объекты. Это свойство специализации. Кроме того, зоны более высокого уровня обычно обобщают информацию, полученную от слоев низкого уровня. Это свойство обобщения или абстракции.

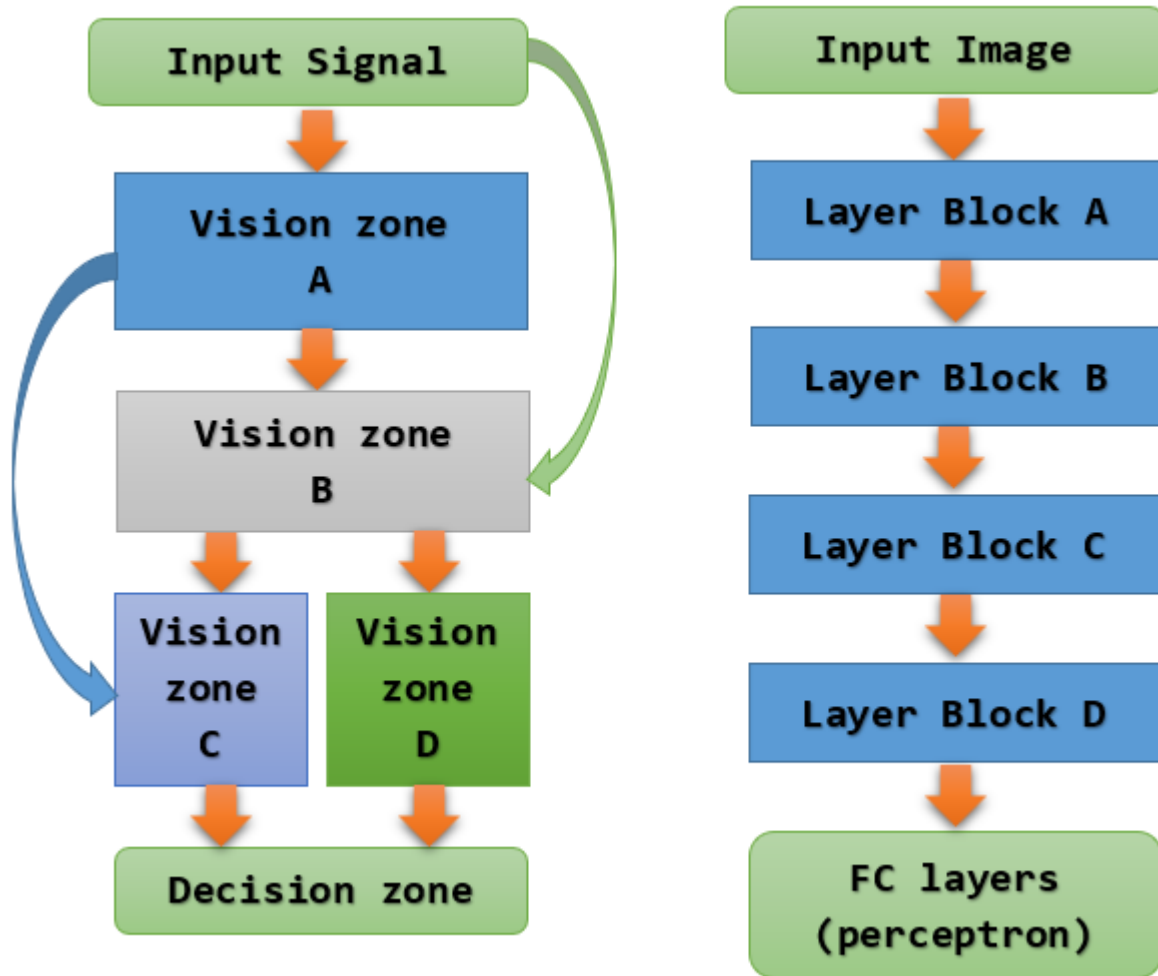
Именно эти принципы функционирования зрительной системы легли в основу создания глубоких сверточных сетей: они состоят из множества слоев, каждый из которых ответственен за выделение определенных признаков. Использование такой архитектуры привело к очередной революции в области ИИ, а именно – революции в распознавании изображений.

Однако, все дальнейшее исследование сверточных нейронных сетей были направлены на то, чтобы добиться большей глубины. Для этого изобретались новые типы сверточных слоев и новые методы обучения, которые позволяли реализовать сеть большей глубины и тем самым, добиться большей точности решения задачи. То есть, все попытки увеличения точности носили характер использования грубой силы – если обучить более глубокую сеть, то получим более точный результат. Это можно легко проследить по количеству слоев в архитектурах, появлявшихся последовательно во времени [7]: AlexNet – 5 слоев; VGG – 19 слоев; Inception – 22 слоя; ResNet – 152 слоя; а последние версии сетей с остаточными связями – до тысячи.

Очевидно, такое развитие является экстенсивным и эволюционным. Для интенсивного или революционного развития в этой области необходимо применение принципиально новых идей в архитектуре. Поскольку первая революция в этой области была достигнута путем заимствования одного из принципов устройства зрительной системы – последовательности слоев, можно предположить, что использование других принципов может так же привести к очередной революции в компьютерном зрении.

Одним из таких принципов является нелинейность структуры зрительной системы. Под нелинейностью здесь понимается непоследовательность связей между зонами зрительной системы, а именно, зона некоторого уровня дает входной сигнал не только зоне следующего уровня, но и другим зонам [7]. Это схематично изображено на рисунке 2 а. В современных сверточных архитектурах, слои связаны последовательно – выходной сигнал слоя поступает только на вход следующего. Отметим, что сеть может состоять из блоков, например, Inception или Residual, внутри которых такая последовательность связи нарушается и присутствует

разветвление. Однако, если рассматривать блоки, то они соединены последовательно (рис. 2 б).



а б
**Рисунок 2. Схематичное изображение связей
а) зон зрительной системы б) блоков нейронной сети**

Кроме того, такие блоки нейронной сети имеют одинаковую структуру. Они могут отличаться количеством внутренних сверточных слоев или функцией активации, однако, принципиального отличия структуры таких блоков нет. То есть блоки выполняют принципиально одинаковые функции в то время, как зоны зрительной системы выполняют принципиально различные функции. Хотя каждая зона состоит из нейронов, очевидно, что 'устройство' зон должно отличаться и быть оптимизировано для выполнения конкретной функции. Значит, архитектура блоков, отвечающих за распознавание различных признаков в сверточных сетях, должна быть принципиально отлична.

Разработка архитектуры нейронной сети, полностью имитирующей структуру зрительной системы на данный момент невозможна. Это связано как с нехваткой знаний об устройстве данной системы, так и отсутствием

готовых инструментов реализации такой архитектуры. На рисунке 3 представлена предлагаемая, очень приблизительная схема подобной архитектуры нейронной сети. Данная схема представлена в качестве иллюстрации идеи предлагаемой архитектуры и не претендует на полноту.

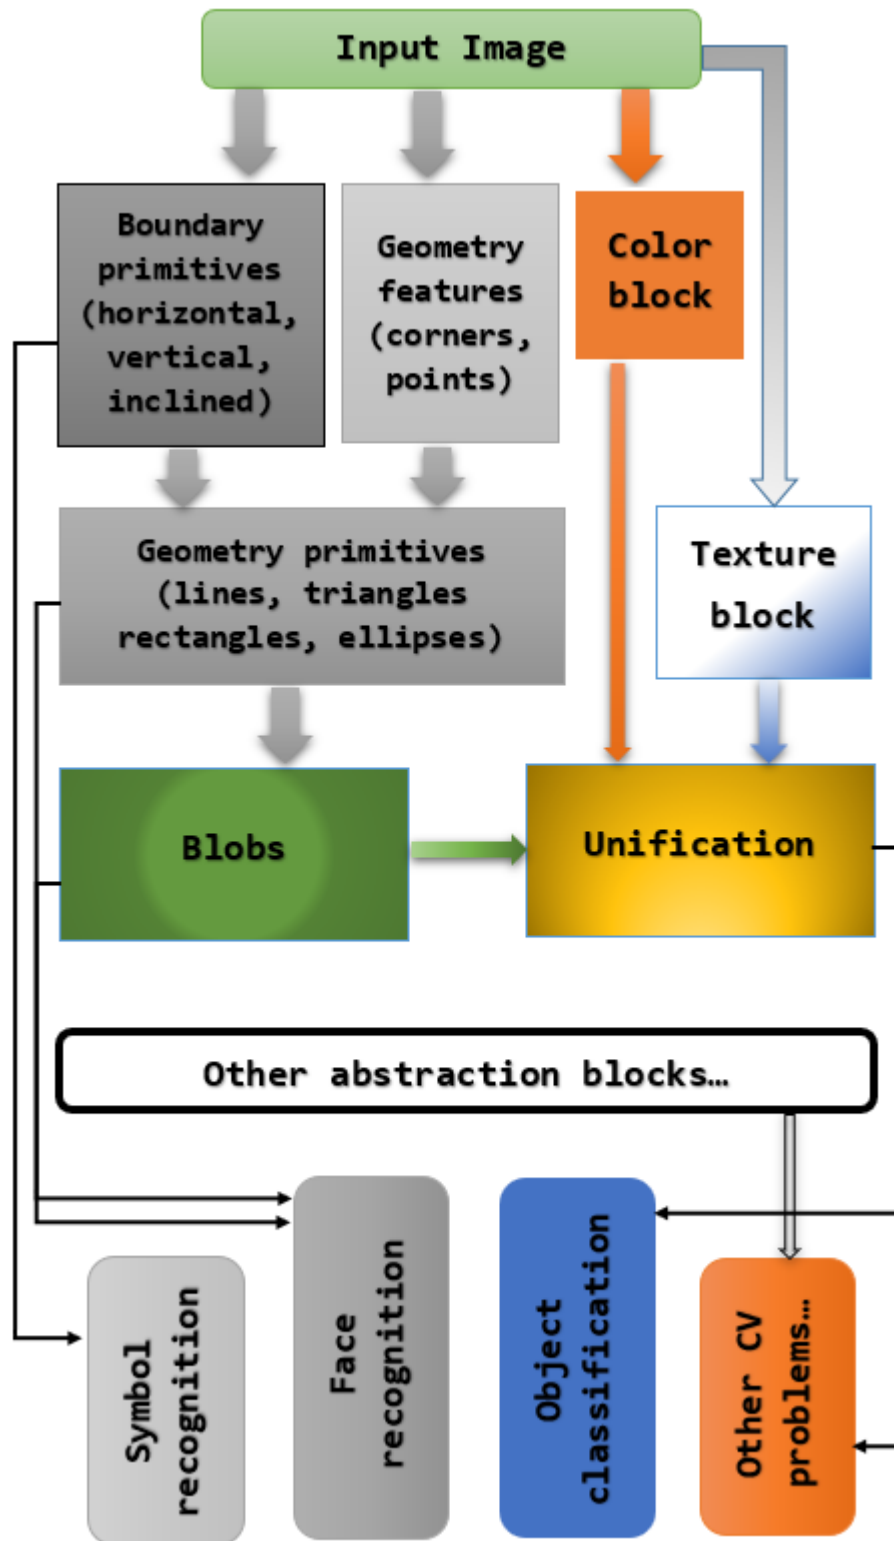


Рисунок 3. Схематичное изображение архитектуры с нелинейными связями

Реализация предлагаемой архитектуры, состоящей из блоков, каждый из которых имеет уникальную структуру, и соединение их непрямыми связями, не решает проблемы переносимого обучения. Дело в том, что данные блоки должны отвечать за определенную функцию искусственной зрительной системы. Простое же обучение на большом объеме данных не сможет гарантировать, что блоки системы ‘научатся’ выполнять именно ту функцию, для которой они разработаны. Для этого необходимы специальные методики обучения.

Для решения проблемы контролируемого обучения предлагается следующее: каждый блок обучать отдельно и именно той функции, за которую они ответственны; каждый блок обучается на своих собственных данных по своей методике; данные, на которых обучаются блоки генерируются искусственно и не включают в себя никакие изображения, которые будут использоваться в конечной нейронной сети, использующей предварительно обученные блоки.

Рассмотрим предложенную методику на реализации блока определения границ Boundary Primitives (рис. 3). Данный блок должен выделить участки на изображении, где есть граница. Будем различать следующие границы: вертикальная, горизонтальная, наклонная вправо, наклонная влево. Каждая граница может иметь два варианта: от светлого к темному и от темного к светлому. Таким образом, имеем всего 8 типов границ.

Для определения каждого типа необходимо обучить свой фильтр (ядро) сверточной сети. Для обучения выбраны фильтры 4x4 пикселя. Для каждого фильтра сгенерирован ‘идеальный’ образец (рис. 4). Поскольку границы могут определяться переходом различной контрастности, для каждого образца генерируется аналогичное изображение, но с различными значениями контрастности границы и различным значением темной части. Всего для обучения 8 фильтров сгенерировано 3920 изображений. Кроме этого, для правильного обучения сгенерированы ‘отрицательные’ образцы – изображения, не содержащие границу.




Рисунок 4. Примеры образцов фильтров 4x4 пикселя для определения границ (вертикальных и наклонных)

Обучение фильтров выполняется как обучение обычного классификатора. Создана нейронная сеть с одним сверточным слоем с 8 ядрами 4x4 пикселя, и одним полносвязным выходным слоем с 8 нейронами. Нейронная сеть обучается на сгенерированных данных, которые размечены для классификации, то есть изображение может принадлежать одному из 8 классов границ.

Обучение такой ‘микро’ сверточной сети происходит очень быстро благодаря малому числу обучаемых параметров $((4 \times 4 + 1) \times 8 = 136)$ и данных (~4000). На процессоре Intel Core i7 время обучения составляет порядка 1 минуты.

Для верификации обученного блока выделения границ можно провести следующий эксперимент: создать нейронную сеть с аналогичным по архитектуре сверточным слоем; перенести значения обученных коэффициентов ядер свертки в данную сеть; провести обработку изображения большего размера, например 64x64 пикселя; вывести карты особенностей (feature maps), полученные при обработке изображения сверточным слоем. На рисунке 5 приведены результаты такого эксперимента на изображении человека.




Рисунок 5. Карты особенностей, полученные блоком выделения границ на изображении человека

Из результатов эксперимента видно, что фильтры действительно ‘научились’ выделять границы. Причем каждый фильтр выделяет границы своего типа: вертикальные границы (первые 2 изображения вверху слева); горизонтальные границы (два изображения вверху справа); наклонные границы (четыре изображения во втором ряду); на изображении внизу слева приведена суммарная карта особенностей.

Таким образом, проведено контролируемое обучение блока выделения границ. Данный блок действительно выделяет те особенности на изображении, которые предполагаются разработчиком, то есть в нейронную сеть заложены некоторые знания. Предполагается, что такое сочетание знаний, имеющихся у эксперта-человека (разработчика нейронной сети или стороннего эксперта в области распознавания), позволят создать более эффективные сверточные нейронные сети. Опыт применения накопленных экспертных знаний для успешного решения сложных математических задач ранее был продемонстрирован в реализации программы REGIONS [8]. Накопленные знания математиков – аналитические решения краевых для канонических тел, были заложены в базу знаний данной программы, что позволило получать высокоточные аналитические решения сложных краевых задач. Получение таких высокоточных решений невозможно без использования априорных знаний, только с позиции грубой силы, например, с помощью численных методов. Проводя аналогию – численные методы пытаются решить задачу с помощью увеличения числа конечных элементов в то время, как современные исследователи сверточных нейронных сетей пытаются увеличить точность распознавания за счет увеличения числа слоев. Предлагаемый подход с использованием контролируемого обучения позволит заложить в нейронную сеть знания эксперта, тем самым сделав ее работу более эффективной и надежной. Кроме того, при применении такой нейронной сети, можно понять, почему она сделала тот или иной вывод, поскольку известно, за какие признаки отвечает тот или иной блок, и даже конкретный нейрон (ядро сверточного слоя).

Продемонстрируем эффективность обученного блока на реализации переносимого обучения при решении задачи о распознавании цифр для автомобильных госномеров. Для этого создана нейронная сеть с обученным блоком распознавания границ (1 сверточный слой) и двуслойным классификатором (промежуточный слой с 64 нейронами и выходной слой с 10 нейронами). Нейронная сеть обучена на 9500 черно-белых изображениях 28x28 пикселей. Тестирующая выборка составляет 500 изображений. Сверточный слой в обучении не участвует, обучаются только полносвязные слои. Время обучения оставило порядка 2 минут. Получены следующие параметры точности: точность обучения – 100%, точность тестирования 99%. После обучения проведена валидация нейронной сети на реальных цифрах, полученных с видеокамеры в реальных ситуациях на автомобильных номерах. Точность составила 95%, среднее время распознавания – 0.04 миллисекунды. Результат активации нейронов для распознавания одной цифры представлен на рисунке 6.

Проведено сравнение результатов с тестами, проведенными на сверточной нейронной сети, специально разработанной для распознавания цифр автомобильных номеров. Данная сеть содержит 2 сверточных слоя с 128 и 64 нейронами соответственно, промежуточный слой классификатора содержит 256 нейронов. Обучение такой сети занимает приблизительно 1-2 часа. Точность обучения и тестирования составила 100%. Точность на

валидационных данных составила 98%, среднее время распознавания – 0.6 миллисекунды.

По результатам сравнения можно сделать вывод, что, хотя нейронная сеть, реализованная на основе предложенного метода переносимого обучения, уступает по точности специализированной нейронной сети, разработанной специально для распознавания цифр, ее производительность выше в 15 раз. Кроме того, время обучения сети на 2 порядка меньше. При этом блок определения границ может быть использован без переобучения для реализации других нейронных сетей, например, распознавания букв на автомобильных номерах. Также следует отметить, что реализованная нейронная сеть содержит только один блок. Реализация других блоков, например, геометрических примитивов, должна позволить добиться точности выше, чем у специализированной нейронной сети.



Рисунок 6. Карты особенностей, полученные блоком выделения границ на изображении цифры

Итак, в работе предложен метод реализации переносимого обучения в компьютерном зрении. Метод основан на контролируемом обучении специальных блоков нейронной сети, которое позволяет заложить в сверточные слои некоторые знания эксперта в области распознавания изображений. Наличие таких специализированных блоков должно приводить к более эффективным и точным нейронным сетям. Применение подхода продемонстрировано на примере решения задачи распознавания цифр. Также предложена новая архитектура нейронной сети с непрямыми связями, основанная на сочетании различных блоков, ответственных за выделение специализированных признаков. Идея такой архитектуры заимствована из устройства зрительной системы человека. Дальнейшее развитие данного

подхода заключается в разработке различных блоков и методов их обучения, реализации данных блоков и нейронной сети с предложенной архитектурой.

Библиографический список

1. Шапиро Л., Стокман Дж. Компьютерное зрение.: Пер. с англ. – 2-е изд. (эл.) – Москва: БИНОМ. Лаборатория знаний, 2013, 752 с.
2. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. – 2-е изд., испр. – М.: ДМК Пресс, 2018. – 652 с.: цв. ил.
3. Rosebrock A. Deep Learning for Computer Vision with Python. Starter Bundle. – pyimagesearch.com, 2017. – 332 p.
4. Rosebrock A. Deep Learning for Computer Vision with Python. Practitioner Bundle. – pyimagesearch.com, 2017. – 210 p.
5. Rosebrock A. Deep Learning for Computer Vision with Python. ImageNet Bundle. – pyimagesearch.com, 2017. – 323 p.
6. Chollet F. Deep Learning with Python. – NY.: Manning Publications Co., 2018. – 386 p.
7. Николенко С., Кадурын А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – СПб.: Питер, 2018. – 480 с.: ил.
8. Гладкий С.Л., Степанов Н.А., Ясницкий Л.Н. Интеллектуальное моделирование физических проблем. Москва–Ижевск: НИЦ «Регулярная и хаотическая динамика», 2006. – 200 с.

KNOWLEDGE BASED TRANSFER LEARNING IN COMPUTER VISION

Sergey L. Gladkiy

LLC «VIPAKS», Krasnova st., 24, Perm, Russia, 614000, lrndlrnd@mail.ru

This article describes some problems of transfer learning in computer vision. One of the transfer learning approaches is using pre-trained convolutional neural networks for feature extraction. In this approach, the problem of datasets inconsistency arises. The second problem is a superfluity of the features in a pre-trained convolutional model. Another problem is that the extracted features are not optimal for solving specific problem. In this work, new methods of transfer learning implementation suggested to solve mentioned problems. The methods are based on special learning approach, which allows to control the extracted feature patterns, and thus, embed some knowledge to the convolutional network. Also, some ideas of new neural network architecture suggested. The ideas based on the human vision system structure.

Key words: artificial intelligence, convolutional neural network, deep learning, transfer learning, computer vision.

ТЕСТИРОВАНИЕ АЛГОРИТМА ЛОКАЛИЗАЦИИ ОПУХОЛИ ПРИ РАКЕ МОЛОЧНОЙ ЖЕЛЕЗЫ НА РЕЗУЛЬТАТАХ МОДЕЛИРОВАНИЯ ТЕМПЕРАТУРНЫХ ПОЛЕЙ⁸

Глазунов Виктор Анатольевич

Волгоградский государственный университет, 400062, Россия, г. Волгоград,
пр. Университетский, 100, ivta-182_287636@volsu.ru

Данная работа выполнена в рамках исследований, посвященных разработке методов интеллектуального анализа медицинских термометрических данных, предназначенных для создания консультативной интеллектуальной системы диагностики рака молочной железы. Был применен разработанный ранее подход к формированию признаков пространства на основе данных микроволновой радиотермометрии и созданный алгоритм локализации злокачественных новообразований в молочной железе. Данный алгоритм является алгоритмом взвешенного голосования, который настраивается с помощью генетического алгоритма. Работа алгоритма была проверена отдельно на результатах моделирования температурных полей молочных желез, а также на реальных данных. Помимо этого, производилась перекрестная проверка его работы на реальных данных и на результатах моделирования. В этих случаях алгоритм локализации может достигать достоверности от 55 до 65% на тестовых выборках.

Ключевые слова: микроволновая термометрия, рак молочной железы, маммология, локализация опухоли, достоверность, интеллектуальный анализ данных, генетический алгоритм, алгоритм взвешенного голосования, термометрические диагностические признаки, кросс-валидация.

Одним из методов диагностики рака молочной железы является микроволновая термометрия. Метод основан на измерении температуры человеческого тела на коже и на глубине нескольких сантиметров. Измерения производятся в следующих точках (рис. 1).




Рисунок 1. 1 Расположение точек измерения на молочных железах

⁸ Публикация подготовлена при финансовой поддержке РФФИ (грант № 19-01-00358).
© Глазунов В.А., 2020

Полученные числовые результаты могут быть обработаны методами интеллектуального анализа данных. Ранее целью такого анализа была задача выявления онкологических заболеваний [1, 2]. В данной работе рассматривается проблема определения местоположения опухоли.

При работе с результатами фактических температурных измерений было обнаружено, что врачи описывают локализацию опухоли в привязке к квадрантам молочных желез. Четыре квадранта дают четыре варианта расположения опухоли. Кроме того, есть описания, где опухоль находится на границе соседних квадрантов или в центре груди. Это добавляет еще пять вариантов локализации. Таким образом, каждую молочную железу можно разделить на 9 областей, которые обозначены буквой d . Их количество и расположение соответствуют точкам измерения температуры, поэтому участки нумеруются так же, как и соответствующие точки измерения (рис. 2).




Рисунок 2. 2 Схема расположения областей

Были рассмотрены различные модели распределения опухолей по регионам. В рамках строгой модели считается, что опухоль занимает строго одну область d_i . Однако для врача менее точное указание местоположения опухоли, но с большей степенью уверенности может иметь большее значение. Поэтому была рассмотрена и нестрогая модель распределения опухолей, в рамках которой опухоль во внешних областях дополнительно занимает две смежные области. Другими словами, если в строгой модели опухоль занимает область d_2 , то в нестрогой – d_1, d_2, d_3 .

С использованием строгой модели не удастся достигать подходящих результатов, поэтому далее используется только нестрогая модель.

При создании пространства признаков, предназначенного для решения задачи локализации злокачественного новообразования, за основу были взяты функции из полученных ранее признаков [2].

Признаком локализации будем называть четверку (f, Y, X, N) , состоящую из функции от температур f , критерия качества Y , множества X и набора областей молочной железы N . Где X является подмножеством области значений f , к N относятся области d_i , для которых выполнение признака увеличивает вероятность наличия опухоли.

Если для признака заданы f, N и множество X , то для него могут быть найдены чувствительность (Sensitivity) и специфичность (Specificity).

В качестве Y применялось среднее гармоническое между чувствительностью и специфичностью, эта величина хорошо

zareкомендовала себя в работе [2]. Оптимальное множество X для признака находится в процессе максимизации величины Y при фиксированных f и N.

$$Y = \frac{2 * Sensitivity * Specificity}{Sensitivity + Specificity}$$

В таблице 1 приводятся некоторые примеры полученных признаков.

Таблица 1 – Примеры признаков локализации

Функция f	Критерий Y	Множество X	Набор N
$t_{0 ИК} - t_{7 ИК}$	0,66	$(-\infty; 0,21)$	d7
$(t_{3 РТМ} + t_{2 РТМ}) / 2 - (t_{3 ИК} + t_{2 ИК}) / 2$	0,60	$(1,47; +\infty)$	d2, d3
$t_{0 РТМ} - (t_{7 РТМ} + t_{6 РТМ}) / 2$	0,59	$(-\infty; -0,30)$	d6, d7
$t_{ср.РТМ} - (t_{1 РТМ} + t_{8 РТМ}) / 2$	0,51	$(-\infty; 0,31)$	d1, d8

Более подробное описание признаков локализации приводится в [3].

В качестве алгоритма локализации использовался алгоритм взвешенного голосования признаков. В качестве веса i-го признака использовалась следующая величина:

$$k_i * \frac{Y_i}{NCount_i}$$

Здесь Y_i – критерий качества i-го признака, $NCount_i$ – количество областей в наборе N_i признака, а k_i – дополнительный коэффициент. Деление на $NCount_i$ применялось для учета того, что признак может повышать вероятность нахождения опухоли сразу в нескольких областях d_j .

Достоверность (Accuracy) применялась в качестве основного показателя успешности работы алгоритма локализации.

$$Accuracy = \frac{TN + TP}{TN + FN + TP + FP}$$

где TN – количество верных отрицательных результатов (опухоль действительно отсутствует), TP – количество верных положительных результатов (действительно обнаружили опухоль), FN – количество ошибочных отрицательных результатов (опухоль не обнаружена там, где она есть), FP – количество ошибочных положительных результатов (опухоль обнаружена там, где ее в действительности нет).

Для задачи подбора коэффициентов k применялся генетический алгоритм [4], поскольку максимальное количество признаков в наборе может достигать до 200. Также применялась минимизация наборов признаков с использованием генетического алгоритма.

Более подробное описание алгоритма локализации приводится в [3].

В [5] Поляковым М. В. были смоделированы температурные поля молочных желез, в том числе пораженных злокачественными новообразованиями. Было принято решение проверить модельные данные с помощью алгоритма локализации и сверить полученные результаты с результатами работы алгоритма на фактических данных.

Всего модельные данные включают информацию по 160 молочным железам с злокачественными опухолями. Они не были разбиты на пациентов, потому такое разбиение осуществлялось искусственно в случайном порядке. По этой причине пришлось отказаться от использования признаков, которые сравнивают температуры различных молочных желез пациента (термоассиметрия). Полученный набор данных включает информацию по 80 пациентам. При проверке применялась кросс-валидация по методу Монте-Карло, в процессе которой исходный набор данных случайным образом делился на обучающую и тестовую выборку в соотношении 2 к 1. Применялось по 10 обучающих и тестовых выборок, полученные результаты усреднялись.

В качестве фактических использовались данные, полученные с использованием температурного датчика номер 6. Всего в этот набор входят данные по 75 пациентам, у которых 77 молочных желез поражены злокачественными новообразованиями. При проверке алгоритма применялась кросс-валидация аналогично модельным данным.

Также производилось перекрестная проверка: обучение алгоритма на фактических данных с проверкой на модельных и обучение на модельных данных с проверкой на фактических. В этих случаях также применялась кросс-валидация. Для этого полученные ранее обучающие выборки попеременно играли роль обучающих или тестовых. Например, в случае обучения на модельных данных полученные для них обучающие выборки оставались обучающими, а обучающие выборки фактических данных становились тестовыми.

Таблица – 2 Результаты проверки алгоритма локализации

Тип проверки	Выборка	Достоверность
Фактические данные	Обучающая	81,21%
	Тестовая	64,02%
Модельные данные	Обучающая	75,99%
	Тестовая	62,79%
Обучение на модельных с проверкой на фактических	Обучающая	74,01%
	Тестовая	54,72%

Обучение на фактических с проверкой на модельных	Обучающая	81,61%
	Тестовая	54,53%

Результаты на модельных данных незначительно уступают фактическим, а результаты перекрестной проверки оказались очень близкими друг к другу. Из этого можно сделать осторожный вывод, что при моделировании не были пропущены какие-то существенные особенности в температурном распределении опухолей, ведь в этом случае при обучении на модельных данных результаты на фактических должны были бы быть намного хуже.

Однако некоторая разница между фактическими и модельными данными все же имеется, поскольку перекрестная проверка дает на 10% меньшую достоверность на тестовых выборках.

Благодарность. Исследование выполнено при финансовой поддержке РФФИ, проект «Математические модели радиационных полей и анализа данных микроволновой радиотермометрии в ранней диагностике рака молочных желез» № 19-01-00358.

Библиографический список

1. *Зенович А. В., Петренко А. Ю.* Построение настраиваемого медиком классификатора онкологических заболеваний молочных желез методом комбинированной термометрии. //Инженерный вестник Дона, 2019, № 5.
2. *Лосев А. Г., Левшинский В. В.* Интеллектуальный анализ термометрических данных в диагностике молочных желез // УБС. 2017. №70. С. 133-135.
3. *Глазунов В. А, Лосев А. Г.,* Алгоритм локализации опухоли при раке молочной железы по данным микроволновой термометрии. //Инженерный вестник Дона, 2019, № 7.
4. *Карпенко А.П.* Современные алгоритмы поисковой оптимизации. Алгоритмы вдохновленные природой. М.: Издательство МГТУ им. Н.Э Баумана, 2014, С. 65-95.
5. *Поляков М.В., Хоперсков А.В.* Вычислительные эксперименты для исследования радиационных и тепловых полей в биотканях. //Инженерный вестник Дона, 2019, № 5.

TESTING THE ALGORITHM OF TUMOR LOCALIZATION IN BREAST CANCER ON THE RESULTS OF TEMPERATURE FIELD SIMULATION

Glazunov Viktor A.

Volgograd State University, 100, University ave., Volgograd, 400062, Russia,
ivta-182_287636@volsu.ru

This work was carried out as part of research on the development of methods for the intelligent analysis of medical thermometric data. These methods are designed to create a consultative intelligent system for the diagnosis of breast cancer. The previously developed approach to the formation of the feature space based on microwave radiothermometry data and the created algorithm for the localization of malignant neoplasms in the mammary gland were applied. This algorithm is a weighted voting algorithm that is configured using a genetic algorithm. The operation of the algorithm was tested separately on the results of modeling the temperature fields of the mammary glands, as well as on real data. In addition, it was cross-checked against real data and simulation results. In these cases, the localization algorithm can achieve accuracy from 55 to 65% on test samples.

Key words: microwave thermometry, breast cancer, mammology, tumor localization, reliability, data mining, genetic algorithm, weighted voting algorithm, thermometric diagnostic signs, cross-validation.

УДК 004.89

НЕЙРОННЫЕ СЕТИ И РЕГРЕССИОННЫЙ АНАЛИЗ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ⁹

Дубовская Виктория Игоревна, Лосев Александр Георгиевич

Волгоградский государственный университет, 400062, Россия, г. Волгоград,
просп. Университетский, 100, dubovskajav@volsu.ru

Настоящая работа посвящена изучению зависимости температурных полей молочных желез от температуры окружающей среды, а также параметров анамнеза и предварительного обследования пациенток. Как следствие, удастся значительно усовершенствовать пространство термометрических диагностических признаков, предназначенное для консультативной интеллектуальной системы выявления рака молочной железы. Первоначальный набор термометрических признаков, служащий основой консультативной системы, был получен в предшествующих работах А.Г. Лосева и В.В. Левшинского. Для учета влияния на температуру внешних факторов и параметров предварительного обследования, при формировании признакового пространства были предложены модели регрессии,

⁹ Публикация подготовлена при финансовой поддержке РФФИ (грант № 19-01-00358) .
© Дубовская В.И., Лосев А.Г., 2020

построенные методом нейросетевого моделирования. Данные модели обладают достаточной производительностью, а также низким значением ошибки, что позволяет использовать их на практике, в отличие от линейных моделей.

В результате масштабирования базы термометрических данных путем использования регрессионных моделей, стало возможным проведение анализа влияния ранее выявленной неоднородности данных в разрезе возраста и диаметра молочных желез на эффективность высокоинформативных диагностических признаков.

Ключевые слова: искусственная нейронная сеть, микроволновая радиотермометрия, рак молочной железы.

Отличительной чертой современной медицинской диагностики является все более активное применение методов и алгоритмов искусственного интеллекта. В частности, разработка консультативно-диагностических систем отмечена как приоритетное направление в дорожной карте развития «сквозной» цифровой технологии «Нейротехнологии и искусственный интеллект». Подобные системы способны учитывать тонкие классификации и сложные взаимосвязи признаков. В данном направлении имеют огромный потенциал нейронные сети. Их применение при работе с медицинскими данными позволяет повысить точность и достоверность полученных результатов [1-3].

На сегодняшний день рак молочной железы (РМЖ) является одним из наиболее распространенных и опасных онкологических заболеваний. При этом, традиционные методы обследования, применяемые в течение последних десятилетий (рентгенография, маммография и др.) не решили задачу раннего выявления РМЖ. В последние годы активно развивается метод микроволновой радиотермометрии, который позволяет осуществлять раннюю диагностику за счет неинвазивного определения температуры внутри органов пациентов [4].

С момента своего зарождения основной областью применения РТМ-метода является маммология. В ряде работ отмечено, что использование микроволновой радиотермометрии в комбинации с методами искусственного интеллекта, показывает высокую эффективность в ранней диагностике заболеваний (см., например [1; 2; 5; 6]).

Для диагностики молочных желез в большинстве клиник используется измерительный комплекс РТС-01-РЭС, при помощи которого фиксируются 44 температуры в РТМ-диапазоне (глубинные) и ИК-диапазоне (кожные). В результате проведенных специалистами исследований был выявлен ряд высокоэффективных термометрических признаков заболевания, а именно: разница температур сосков, повышенная термоасимметрия между

одноименными точками правой и левой молочной железы, повышенный разброс температур между отдельными точками молочной железы, являющейся пораженной, соотношение кожной и глубинной температур и другие [5; 6].

В процессе применения метода микроволновой радиотермометрии было выявлено значимое влияние на температурные поля таких факторов, как температура окружающей среды, диаметр МЖ, возраст пациентки и т.д. В данном исследовании было принято решение производить учет данных факторов при формировании признакового пространства с помощью использования регрессионных моделей, построенных на базе соответствующих нейронных сетей.

В предшествующих работах была проведена проверка гипотезы об однородности выборок термометрических данных по диаметру молочной железы, месту обследования, возрасту пациентки, типу датчика [7]. Исходя из полученных результатов, было принято решение о разделении данных на две группы по возрасту, а также на три группы, в зависимости от диаметра молочной железы. Соответственно, нейронные сети были построены для каждой группы отдельно.

В данной работе использовалась база термометрических данных, которая содержит информацию об обследованиях 1419 пациенток, имеющих диаметр молочных желез менее 21 см, 922 пациенток с диаметром в диапазоне 22-26 см, 404 – с диаметром более 27 см. В первую возрастную группу (до 40 лет) входит 1288 пациенток, во вторую (более 40 лет) – 1242.

Для построения регрессионных моделей использовался пакет Statistica. Независимыми параметрами выступали такие внешние факторы как температура окружающей среды, день цикла, индекс массы, возраст и диаметр молочной железы пациентки. На первом этапе исследования были рассмотрены модели, в которых зависимой переменной выступает температура молочной железы в конкретной точке. Однако, проведенный анализ, показывают, что диагностика, основанная только на значениях температур, не позволяет достичь максимальной эффективности. Поэтому, в расширение данного подхода, регрессионные модели были построены не только для температур молочных желез, но и для моделирующих функций, которые представляют собой математическую формализацию известных эвристик и описывают нюансы поведения температур желез пациенток различных контрольных классов.

В качестве архитектуры нейронных сетей в данной работе был выбран многослойный персептрон, так как он является наиболее подходящим для решения задач нелинейной регрессии. Количество скрытых узлов обработки, фактически определяющих уравнение прогноза, выбирается программой

Statistica. Минимальное количество скрытых нейронов 3, максимальное – 9. Аналогичным образом происходит определение функции активации скрытых и выходных нейронов. Представлены следующие функции: тождественная, логистическая, гиперболическая, экспоненциальная и синусоидальная. Для минимизации эффекта переобучения использовалась регуляризация весов, которая контролирует сложность обучаемых сетей.

Вся статистика генерируется независимо для обучающих и тестовых выборок. Цель алгоритма поиска подходящей нейронной сети заключается в переборе ряда нейросетевых конфигураций и выбора наилучшей с точки зрения минимума ошибки на выходе сети, которая представляет собой функцию ошибок, усредненную по всему множеству, и максимума производительности. Показатель производительности характеризует качество прогнозирования сети, т.е. степень соответствия выходных значений целевым.

Некоторые примеры полученных результатов приведены ниже. При этом выбраны следующие информативные признаки: внутренний градиент молочной железы (MG001, MG002), разброс температур (MG029, MG035), евклидово расстояние между внутренними температурами железы (MG040).

Таблица 1 – Регрессионные модели, построенные инструментами нейросетевого моделирования (выборки по диаметру молочной железы)

Признак	Диаметр	Сеть	Производительность		Ошибки	
			Обучающая	Тестовая	Обучающая	Тестовая
MG002	Общий	MLP 5-9-1	0.51	0.30	0.19	0.24
	<21	MLP 5-3-1	0,50	0,31	0.19	0.17
	22-26	MLP 5-9-1	0.50	0.51	0.16	0.15
	>27	MLP 5-9-1	0.47	0.58	0.20	0.37
MG029	Общий	MLP 5-10-1	0.37	0.11	0.01	0.01
	<21	MLP 5-8-1	0.27	0.24	0.01	0.02
	22-26	MLP 5-5-1	0.53	0.24	0.01	0.01
	>27	MLP 5-8-1	0.33	0.58	0.04	0.01
MG040	Общий	MLP 5-8-1	0.42	0.27	0.21	0.37
	<21	MLP 5-3-1	0.43	0.49	0.21	0.16
	22-26	MLP 5-6-1	0.21	0.35	0.01	0.01
	>27	MLP 5-10-1	0.50	0.81	0.32	0.06

На основе данных, указанных в таблице 1, можно сделать вывод, что разделение данных на отдельные выборки относительно диаметра молочной железы способствует увеличению производительности сетей и снижению ошибки.

Таблица – 2. Регрессионные модели, построенные инструментами нейросетевого моделирования (выборки по возрасту)

Признак	Возраст	Сеть	Точность		Ошибки	
			Обучающая	Тестовая	Обучающая	Тестовая
MG002	Общий	MLP 5-9-1	0.51	0.30	0.19	0.24
	<40	MLP 5-4-1	0.41	0.62	0.26	0.13
	>40	MLP 5-5-1	0.51	0.56	0.13	0.15
MG029	Общий	MLP 5-10-1	0.37	0.11	0.01	0.01
	<40	MLP 5-8-1	0.40	0.65	0.01	0.01
	>40	MLP 5-4-1	0.36	0.49	0.02	0.012
MG040	Общий	MLP 5-8-1	0.42	0.27	0.21	0.37
	<40	MLP 5-4-1	0.35	0.46	0.17	0.25
	>40	MLP 5-5-1	0.53	0.64	0.27	0.28

Аналогично предыдущему результату, деление данных на возрастные группы способствовало улучшению показателей моделей, при этом в данном случае, эффект выражается более существенно. Это может быть обусловлено неоднородностью данных, связанных со структурными изменениями, которые происходят в молочных железах пациенток после 40 лет.

Нейронные сети позволяют масштабировать применяемую базу термометрических данных. Для этого предполагается приведение температурных данных к оптимальным условиям. Проводился расчет эффективности исходных признаков (набор 1), имеющих в базе, и полученных с помощью регрессий (набор 2). С целью оценивания эффективности элементов признакового пространства, а также диагностических методов, используются такие показатели как чувствительность, специфичность. В случае несбалансированных выборок критерием эффективности является мера, определенная как среднее геометрическое специфичности и чувствительности [8].

Осуществлялся следующий алгоритм работы:

1. Нахождение оптимальных значений параметров функции регрессии – температуры окружающей среды, размера молочных желез, индекса массы, возраста и т. д.

2. Расчет значения функции регрессии при параметрах, соответствующих конкретной пациентке из базы обследований.

3. Расчет приращения – разности между значением моделирующей функции признака этой пациентки и значением функции регрессии.

4. Суммирование значения функции регрессии при начальных значениях параметров и полученного приращения.

5. Расчет и сравнение эффективности заданных признаков.

Таблица 3 – Эффективность высокоинформативных признаков

Признак	Интервал (набор 1)	Интервал (набор 2)	Эффективность (набор 1)	Эффективность (набор 2)
MG001	2.17, ∞	1.8, ∞	0.49	0,5
MG002	1.71, ∞	1.55, ∞	0.46	0.69
MG029	∞, 0.34	∞, 0.27	0.41	0.45
MG035	0.39, ∞	0.99, ∞	0.75	0.42
MG040	1.9, ∞	1.19, ∞	0.5	0.6

Увеличение эффективности наблюдается во всех рассматриваемых признаках, за исключением разброса температур левой молочной железы. Таким образом, результаты исследования подтверждают необходимость учета выявленных ранее неоднородностей данных в разрезе возраста и диаметра молочных желез. Построенные для каждой выборки отдельно, нейронные сети позволяют масштабировать базу термометрических данных, а также достигать более высокой эффективности высокоинформативных признаков и, следовательно, увеличивать точность и достоверность результатов диагностики.

Библиографический список

1. Веденяпин Д. А., Лосев А. Г. Об одной нейросетевой модели диагностики венозных заболеваний // Управление большими системами: сборник трудов. 2012. № 39. С. 219–229.
2. Лосев А.Г., Медведев Д.А. Применение нейронных сетей в диагностике рака молочной железы по данным микроволновой радиотермометрии // Современная наука и инновации. 2019. Т. 4. № 28. С. 22-28.
3. Yasnitsky L.N., Dumler A.A., Poleshuk A.N., Bogdanov C.V., Cherepanov F.M. Artificial Neural Networks for Obtaining New Medical Knowledge: Diagnostics and Prediction of Cardiovascular Disease Progression // Biology and Medicine (Aligarh). 2015. V. 7. Is. 2. P. BM-095-15.
4. Vesnin S., Turnbull A.K., Dixon J.M., Goryanin I. Modern Microwave Thermometry for Breast Cancer// Journal of Molecular Imaging & Dynamics. 2017. V. 7, Is. 2. DOI: 10.4172/2155-9937.1000136.
5. Levshinskii V., Galazis C., Ovchinnikov L., Vesnin S., Losev A., Goryanin I. Application of Data Mining and Machine Learning in Microwave Radiometry (MWR)// Communications in Computer and Information Science. 2020. V. 1211 CCIS. p. 265 – 288.
6. Лосев А. Г., Левшинский В. В. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы // Математическая физика и компьютерное моделирование. 2017. № 5 (342). С. 16-22.
7. Мазепа Е.А., Дубовская В.И. Пространство термометрических признаков в задаче диагностики рака молочной железы // Современная наука и инновации. 2019. Т. 4. № 28. С. 39-50.

8. Bekkar M., Djema H., Alitouche T. A. Evaluation measures for models assessment over imbalanced data sets // Journal of Information Engineering and Applications. 2013. Vol. 3, no. 10. P. 27–38.

NEURAL NETWORKS AND REGRESSION ANALYSIS IN THE DIAGNOSIS OF BREAST CANCER

Dubovskaya Victoria I., Losev Alexander G.

Volgograd State University, 100, University avenue, Volgograd, 400062, Russia,
dubovskajav@volsu.ru

This work is devoted to the study of the dependence of the temperature fields of the mammary glands on external conditions and the parameters of the anamnesis, and preliminary examination of patients. As a result, it is possible to significantly improve the space of thermometric diagnostic signs intended for the use of an intelligent system for detecting breast cancer. The initial set of thermometric features that serve as the basis of the Advisory system was obtained in previous works by A. G. Losev and V. V. Levshinsky. To take into account the influence of external factors and parameters of the preliminary survey on the temperature, regression models constructed by the neural network modeling method were proposed during the formation of the feature space. These models have sufficient performance, a low error value, which allows them to be used in practice, in contrast to linear models. As a result of scaling the database of thermometric data by using regression models, it became possible to analyze the impact of previously identified heterogeneity of data in the context of age and diameter of mammary glands on the effectiveness of highly informative diagnostic features.

Key words: artificial neural network, microwave radiothermometry, breast cancer.

УДК 004.415.2

РАЗРАБОТКА И РЕАЛИЗАЦИЯ ПРИЛОЖЕНИЯ ДЛЯ ГЕНЕРАЦИИ МЕЛОДИЙ С ПОМОЩЬЮ ГЕНЕТИЧЕСКОГО АЛГОРИТМА

Кузнецова Яна Дмитриевна, Морозенко Владимир Викторович

Национальный исследовательский университет «Высшая школа экономики»,
614070, Россия, г. Пермь, ул. Студенческая, 38, jancuz@yandex.ru

В статье представлено описание приложения для генерации музыки, основанного на использовании генетического алгоритма и искусственной нейронной сети для вычисления функции приспособленности (фитнес-функции). Приложение позволяет создавать оригинальные мелодии на основе изначально задаваемых пользователем образцов определенного музыкального жанра (блюз, кантри, диско и пр.), которые при выполнении

генетического алгоритма «эволюционируют» и оцениваются нейронной сетью для определения принадлежности жанру, заданному пользователем. Использование генетического алгоритма, фитнес-функция которого вычисляется с помощью обученной нейронной сети, решающей задачу классификации музыки, позволяет автоматизировать процесс генерации оригинальных мелодий заранее заданного жанра.

Ключевые слова: генетический алгоритм, нейросетевые технологии, генерация мелодий, классификация музыки, распознавание жанра.

В современном мире большое внимание уделяется защите авторских прав, в том числе на музыкальные произведения. По этой причине разработчики мобильных приложений и компьютерных игр не могут использовать известные популярные мелодии без согласия автора. У них возникает необходимость генерировать мелодии самостоятельно. Поскольку потребность в таких мелодиях очень велика, «сочинять» их массово и в ручном режиме становится сложной творческой задачей.

В связи с внедрением во многие сферы жизни компьютерных технологий, использующих генетические алгоритмы (ГА) и искусственные нейронные сети (ИНС), появилась возможность автоматизации и такого творческого процесса, как создание музыки. Использование для этих целей ГА и ИНС, благодаря заложенным в них механизмам моделирования недетерминированных процессов эволюции, позволяет достичь оригинальности, непредсказуемости и «благозвучности» создаваемых мелодий.

Генетические алгоритмы являются подходящим способом для решения задач оптимизации на слабо формализованном пространстве, особенно в случае, когда область поиска настолько велика, что полный перебор вариантов невозможен за разумное время. Генерацию мелодий, наилучших с точки зрения набора критериев, задаваемых пользователем, вполне может рассматриваться как задача оптимизации [1].

Так как в ходе работы ГА оценивание каждой сгенерированной мелодии относительно заданного набора критериев вручную требует больших трудозатрат и является неоднозначным процессом (в силу неоднозначности самих критериев) было решено использовать систему классификации жанров музыки, основанную на использовании ИНС.

Существует множество музыкальных жанров, уместных или неуместных для использования в тех или иных мобильных приложениях и компьютерных играх. Кроме того, у каждого человека имеются свои музыкальные предпочтения. В связи с этим становится очень важной задачей жанровой классификации музыки, которая в данном случае решается с помощью обученной нейронной сети.

Для рассматриваемой предметной области существует ограниченный выбор специализированного ПО (платформа «GENOM», «GenJam» (Д. Байлз)). Однако ни одно из имеющихся решений не является абсолютно автоматизированным и требует постоянного участия человека для оценки

каждой сгенерированной мелодии по заданному набору критериев, либо не учитывают возможность создания мелодий различных жанров, настройки параметров ГА (размер генерируемой популяции, количество итераций, различные варианты скрещивания, процент мутаций и т.п.) [2, 3]. Таким образом, в отличие от работ [2, 3], для генерации мелодий предлагается использовать ГА с возможностью корректировки параметров, а для вычисления фитнес-функции – нейронную сеть, решающую задачу жанровой классификации мелодий. В итоге решение задачи генерации мелодии сводится сначала к процессу обучению ИНС, классифицирующей музыку по жанрам, а затем использованию обученной ИНС и разработанного ГА для генерации «приятно звучащих» мелодий, отвечающих заданному набору критериев.

Предлагается следующая структура системы генерации мелодий.

1. Блок для непосредственной генерации мелодий, включающий:
 - 1.1) скрещивание (выбор случайным образом «Родителей», одноточечный кроссинговер, создание новой «Популяции»),
 - 1.2) мутацию (выбор случайным образом мелодии из сгенерированной «Популяции», изменение одной ноты/изменение фрагмента мелодии/перестановка фрагментов мелодии).
2. Блок для оценки мелодий, включающий: создание модели ИНС для жанровой классификации мелодий,
 - 2.2) извлечение данных (признаков) из мелодий (расчет характеристик),
 - 2.3) оценка мелодий с использованием созданной модели,
 - 2.4) селекция мелодий определенных жанров.

Так как мелодия представляет собой сложную структуру, включающую в себя такие характеристики, как мелодическая линия, лад, гармония, ритм, логические связи между частями композиции [4], то необходимо разбить её на некоторые составляющие, декомпозировать её для представления данных в системе. Основной единицей мелодии является нота. Информацию о ней (название, октава, время начала воспроизведения, длительность воспроизведения) предлагается использовать в качестве элементов базовой структуры работы в системе. Для работы с музыкальными фрагментами при выполнении скрещивания и мутации было решено использовать файлы с расширением .mid/.midi, так как они являются прекрасным форматом для извлечения интересующей информации о мелодии.

Для обучения ИНС предлагается извлекать следующие характеристики мелодий, представляющие особенную ценность для жанровой классификации, выявленные в результате анализа литературных источников [4-7]:

1. Признаки формы спектра:
 - 1.1. Мел-частотные кепстральные коэффициенты – моделируют характеристики человеческого голоса.
 - 1.2. Спектральный центроид – центр масс звука (равномерное распределение частот характерно для таких жанров, как блюз, классика, регги).

- 1.3. Спектральный спад частоты, спектральная ширина – зависимость высоты тона звука (используется для выявления высоких тонов, которые характерны для таких жанров, как металл, рок).
2. Временной признак: частота перехода через ноль – характеризует наличие ударных инструментов в музыкальных фрагментах (чем больше частота, тем вероятнее использование ударных, а использование ударных инструментов является отличительной особенностью для таких жанров, как рок и металл),
3. Энергетический признак: частоты цветности – характеристики описания меры сходства между музыкальными произведениями по определению энергии каждого тона и полутона.

В качестве набора данных предлагается использовать набор данных GITZAN, состоящий из 1000 звуковых дорожек формата .wav длиной 30 секунд и содержащий 10 музыкальных жанров (*blues, classical, country, disco, hip-hop, jazz, metal, pop, reggae, rock*).

Проектирование, обучение, тестирование нейронной сети выполнялись с использованием инструмента Jupyter Lab на языке программирования Python. Для поиска наилучшего варианта архитектуры нейронной сети (количества слоев, эпох для обучения) использован метод GridSearch, идея которого заключается в том, чтобы создать сетку гиперпараметров, испробовать все возможные сочетания предложенных параметров и выбрать наилучший вариант. В качестве параметров для поиска рассматривались следующие варианты: количество эпох 50, 70 и 100, различное количество слоев с различным числом нейронов. В качестве функции активации для скрытого слоя используется *relu*, которая входные значения, меньшие или равные нулю, превращает в ноль, «выпрямляя» получаемое значение, для выходного слоя используется логистическая функция *softmax*.

Был проведен сравнительный анализ функций оптимизации. Как видно из рисунка 1, наилучший результат показала функция оптимизации *adam*, доля правильных ответов которой на тестовых данных составила порядка 0.7 (рисунок слева), а значение функции потерь оказалось минимальным (рисунок справа). В качестве функции потерь выбрана разреженная категориальная перекрестная энтропия, так как она является наиболее подходящей для случаев взаимоисключения классов (мелодия должна принадлежать только одному определенному жанру и не может принадлежать нескольким жанрам одновременно).

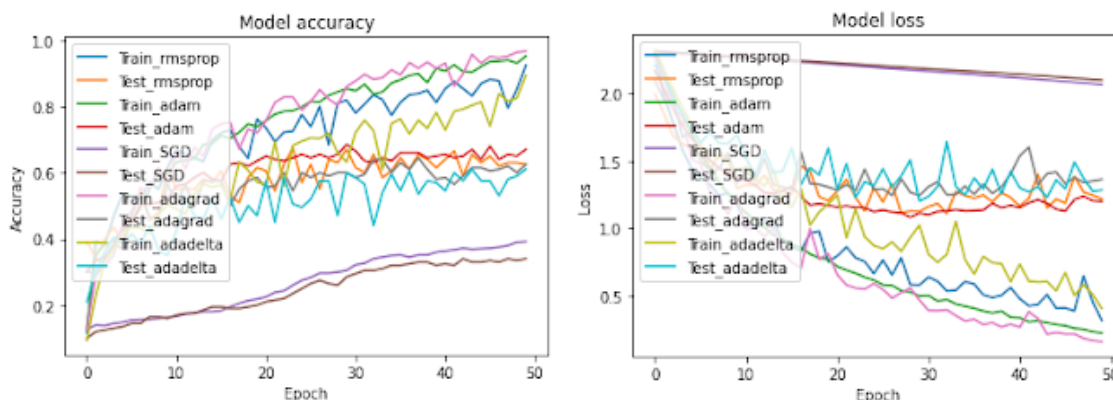


Рисунок 1. Сравнительный анализ функций оптимизации нейронной сети: а) значение доли правильных ответов (accuracy), б) значение функции потерь (loss)

Таким образом, спроектированная после проведенной оптимизации параметров нейронная сеть представляет собой последовательную модель, содержащая четыре слоя. Входной слой представлен двадцатью пятью нейронами, а выходной – десятью.

Для обучения модели данные подвергаются нормализации из-за большого разброса значений рассчитанных характеристик (см. таблицу 1).

Таблица 1 – Средние показатели для каждого признака музыкального жанра

Genre	Chroma stft	Spectral centroid	Spectral bandwidth	rolloff	Zero crossing rate	mfcc1	mfcc20
blues	0,34	1727,66	1931,44	3637,07	0,08	-164,6	-2,79
classical	0,26	1353,99	1521,7	2482,53	0,08	-320,01	-1,07
country	0,34	1896,1	2099,47	3949,25	0,08	-145,05	-3,06
disco	0,42	2619,97	2513,37	5520,11	0,13	-93,71	0,48
hip-hop	0,45	2524,61	2513,52	5333,92	0,12	-103,07	-0,8
jazz	0,3	1792,4	2020,99	3750,38	0,08	-214,54	-2,09
metal	0,48	2602,18	2242,5	5125,2	0,15	-63,06	1,26
pop	0,4	3073,66	3008,24	6655,05	0,13	-67,86	0,31
reggae	0,41	2185,11	2311,49	4594,24	0,09	-162,55	-1,61
rock	0,39	2242,66	2262,86	4669,26	0,11	-110,34	-1,59

Таким образом, обученная нейронная сеть встраивается в работу ГА в качестве «вычислителя» фитнес-функции, а работа всей системы состоит из следующих этапов.

1. Начальный этап (поиск фитнес-функции):
 - 1.1. Задание начальной популяции (мелодии), выбор файлов .mid.
 - 1.2. Конвертация файлов начальной популяции в формат .wav.
 - 1.3. Извлечение данных (характеристик мелодий) из полученной начальной популяции в формате .wav.
 - 1.4. Жанровая классификация (оценка) с использованием ИНС по извлеченным данным из п. 1.3.
 - 1.5. Сохранение информации о жанрах мелодий (фитнес-функция).
2. Генерация мелодий (работа ГА + ИНС):
 - 2.1. Генерация популяции:

- 2.1.1. Выбор родителей случайным образом.
- 2.1.2. Скрещивание (одноточечный кроссинговер).
- 2.2. Мутация (изменение случайной особи).
- 2.3. Селекция мелодий (выбор по фитнес-функции):
 - 2.3.1. Конвертация файлов из .mid в .wav, извлечение данных.
 - 2.3.2. Жанровая классификация с использованием ИНС по извлеченным данным.
 - 2.3.3. Создание следующей популяции, которая становится родительской.
- 2.4. Переход к п. 2.1.

Разработанное приложение протестировано для различных показателей ГА (размер генерируемой популяции – 20, 50, 80, 100; количество итераций – 5, 20, 30, 40, 50; количество мутирующих особей – 5, 25, 50, размер отбираемой популяции – 15, 45, 60, 80). Работа приложения показала следующие результаты.

1. При небольшом размере популяции генерируемые мелодии схожи с изначальными и не отличаются вариативностью.
2. При большом количестве итераций и небольших размерах генерируемой популяции и количестве мутаций, популяция становится однообразной, содержащей однотипные музыкальные фрагменты.
3. При генерации мелодий из контрастных, сильно отличающихся между собой образцов (разных противоположных жанров), чаще получаются мелодии неприятные на слух, чем при генерации мелодий одного жанра.
4. Полученные мелодии в большинстве случаев приятны на слух, однако для генерации мелодий значительно отличающихся от исходных данных (начальная популяция мелодий) необходимо для каждого изначального набора данных подбирать свои параметры для ГА. Средний показатель для данных (получено эмпирически): размер генерируемой популяции – 100, количество итераций – 40; количество мутирующих особей – 25, процент элитизма – 80.

С помощью разработанного приложения были сгенерированы наборы из 10 мелодий каждого жанра. Их благозвучность оценивалась респондентами по трехбалльной шкале. Оценка 2 выставлялась, если мелодия гармонична, приятна на слух, оценка 1 – если мелодия в целом приятна на слух, но является не совсем плавной, содержит резкие переходы, оценка 0 – если мелодия не приятна на слух, ее использование не возможно. По общей оценке респондентов лишь 11 полученных мелодий были оценены пользователями как неблагозвучные и непригодные для дальнейшего использования в компьютерных играх и мобильных приложениях. В то же время 63 мелодии получили наивысший балл, что свидетельствует об удачном опыте применения генетического алгоритма в сочетании с искусственной нейронной сетью для генерации «приятно звучащих» мелодий заранее заданного жанра.

Библиографический список

1. Гладков Л.А., Курейчик В.В., Курейчик В.М. Генетические алгоритмы: Учебное пособие. – 2-е изд. – М.: Физматлит, 2006. – 320 с.
2. Арутюнов В.О., Моделирование музыкального творчества при помощи генетических алгоритмов на базе платформы GENOM. // Программные продукты и системы / Software & Systems № 2 (114), 2016., С. 201-209.
3. Biles J.A. A genetic algorithm for generating jazz solos. // Proc. Intern. Comp. Music Conf., San Francisco, 1994, P. 131-137.
4. Способин И.В. Элементарная теория музыки. М.: ГОСУДАРСТВЕННОЕ МУЗЫКАЛЬНОЕ ИЗДАТЕЛЬСТВО, 1963.
5. Жанровая классификация на Python [Электронный ресурс] URL: <https://proglib.io/p/python-music-classifier> (Дата обращения: 25.02.2020).
6. Scaringella N., Zoia G., Mlynek D. Automatic genre classification of music content: a survey // Signal Processing Magazin, IEEE (Volume 23, Issue 2), 2006. P.21.
7. Peeters G. A large set of audio features for sound description (similarity and classification) in the CUIADO project. CUIADO I.S.T. Project Report, 2004. P.25.

DEVELOPMENT AND IMPLEMENTATION OF APPLICATION FOR GENERATING MELODIES USING A GENETIC ALGORITHM

Kuznetsova Yana D., Morozenko Vladimir V.

National Research University Higher School of Economics,
614070, Russia, Perm, st. Studentcheskaya, 38, jancuz@yandex.ru

The article describes the development of the music generation system based on a genetic algorithm which is used with an artificial neural network as the corresponding fitness function. The application allows you to create melodies which are based on initially set melodies of a certain musical genre selected by the user, which are modified and evaluated by a neural network during the execution of a genetic algorithm to determine whether they belong to the genre specified by the user. Using a genetic algorithm, the fitness function of which is represented by a trained neural network that solves the problem of music classification, allows you to automate the process of generating melodies.

Key words: genetic algorithm, neural network technologies, the generation of melodies, music classification, genres recognition.

КОНЦЕПЦИЯ ПОСТРОЕНИЯ ОНТОЛОГИЧЕСКИ УПРАВЛЯЕМЫХ НЕЙРОИНТЕРФЕЙСОВ

Лабутин Иван Александрович, Чуприна Светлана Игоревна
Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, *barracuda72@bk.ru*

В данной работе представлена концепция авторского подхода к разработке онтологически управляемых нейроинтерфейсов с целью их унифицированной интеграции в произвольную экосистему интернета вещей на основе механизма виртуальной интеграции. Между нейроинтерфейсом и инфраструктурой интернета вещей вводится промежуточный слой – посредник, который с использованием дополнительных знаний в формате онтологий осуществляет интеграцию по модели федерирования. Для построения подобного посредника предлагается использовать как уже разработанные с участием авторов общие методы и средства построения онтологически управляемых решений (в частности, входящие в состав системы научной визуализации SciVi), так и специализированные, разработка которых планируется в составе микросервисной платформы MicroNeuroService. Предполагается, что в качестве подобного посредника может выступать как отдельный программно-аппаратный модуль в составе экосистемы Интернета Вещей, так и программный модуль на стороне нейроинтерфейса, что позволит трансформировать уже существующие нейроустройства в так называемые Smart системы.

Ключевые слова: VCI, нейроинтерфейс, онтологический инжиниринг

Введение

Нейроинтерфейс – программно-аппаратная система, принимающая сигнал биологической природы, снятый с человека, и предсказывающая (в реальном времени/с первой попытки) некоторый абстрактный аспект когнитивного состояния человека [1]. В последнее время в связи с активным расширением сфер применения приложений Интернета Вещей, виртуальной и дополненной реальности бурно развиваются методы и средства управления различными системами на базе нейроинтерфейсов. Поэтому весьма актуальна разработка новых и совершенствование уже имеющихся механизмов встраивания нейроинтерфейсов в существующие системы.

Вопросы *унифицированной* интеграции нейроинтерфейсов в экосистему интернета вещей с целью управления ее компонентами (целевыми системами) до сих пор остаются недостаточно проработанными, несмотря на то, что актуальность разработки подобного рода подходов, методов и средств не вызывает сомнений [2; 3; 4; 5]. В большинстве случаев

оборудование, снимающее сигналы биологической природы (включая и активность головного мозга), способно работать лишь с ограниченным кругом программного обеспечения (ПО), зачастую поставляемого только определенным производителем¹².

Данная статья посвящена описанию концепции построения программных средств, упрощающих и унифицирующих интеграцию программных систем с нейроинтерфейсами на принципах адаптируемости. В основе разработки механизма адаптации лежит расширенный MDA-подход на базе онтологий¹³.

Концепция предлагаемого подхода к разработке онтологически управляемых нейроинтерфейсов

В настоящее время существует два основных подхода к решению задачи интеграции информации [6,7]:

1. Консолидация информации (материализованная интеграция), в основе которой лежит создание единого хранилища, периодически пополняемого из интегрируемых источников данных с помощью специальных модулей, ответственных за извлечение, преобразование и загрузку данных (архитектура «хранилище – ETL-модули»).

2. Федерирование информации (виртуальная интеграция), в которой в качестве центрального элемента системы интеграции выступает так называемый посредник, выполняющий преобразование поступающих запросов в подзапросы к источникам данных; взаимодействие посредника и источников данных осуществляется при помощи специальных модулей – адаптеров (архитектура «посредник – адаптер»).

Учитывая специфику нейроинтерфейсов как систем, генерирующих непрерывный поток данных в реальном времени, представляется наиболее перспективной интеграция нейроинтерфейсов в экосистему Интернета Вещей на принципах виртуальной интеграции. В качестве источников данных здесь выступают датчики различного типа, которыми может быть оснащен нейроинтерфейс (EEG, fNIRS и др.). На сегодняшний день уже разработаны онтологии предметной области, описывающие различные аспекты BCI (Brain-Computer Interface, интерфейс «мозг-компьютер») и их взаимодействие с внешним миром [8, 9]. На рис. 1 приведен фрагмент онтологии BCI-O, относящаяся к описанию непосредственно нейроинтерфейса (понятие `bci:Device` и смежные). Однако, насколько нам известно, до сих пор не существует универсального решения, способного на основе подобных онтологий решать задачу интеграции нейроинтерфейсов с системами класса IoT. В данной статье мы предлагаем концепцию подобной системы, управляемой онтологиями.

¹² Именно так дело обстоит, например, с имеющимся в распоряжении ПГНИУ устройством BE Plus LTM (<http://www.ebneuro.com/en/neurology-en/eeeg-galileo-en/be-plus-ltm>)

¹³ OMG Model Driven Architecture. URL: <http://www.omg.org/mda/>

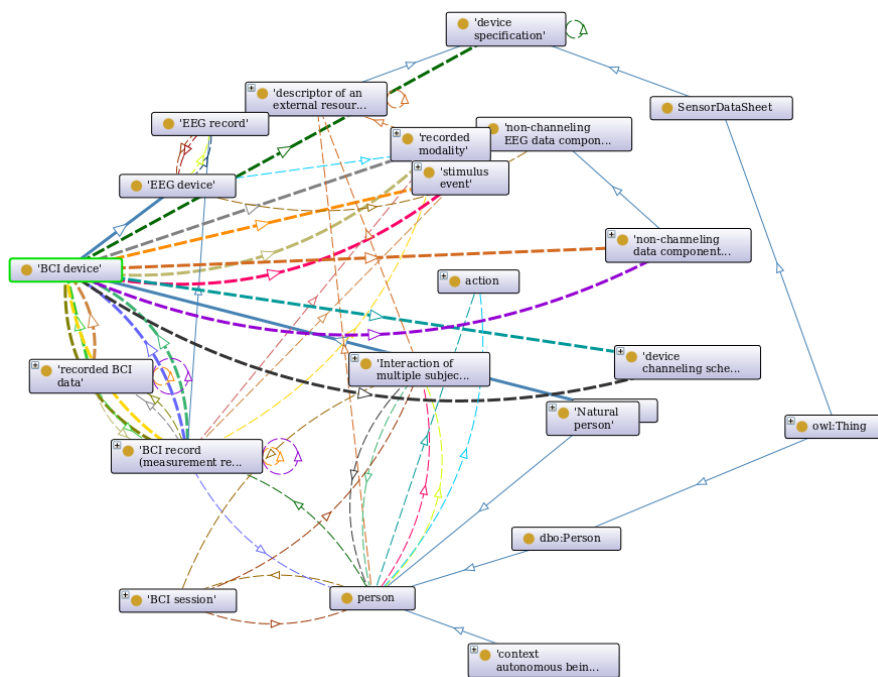


Рисунок1. Фрагмент онтологии VCI-O [7,8]

Интерфейсы мозг-компьютер представляют собой универсальный с точки зрения подачи управляющих команд способ взаимодействия человека и окружающей его вычислительной среды. Основываясь на нашем опыте и опыте наших коллег в области человеко-машинных интерфейсов, управляемых онтологиями [10], мы предлагаем механизм интеграции интерфейсов мозг-компьютер в инфраструктуру интернета вещей путем введения промежуточного слоя – посредника, который будет отвечать за коммуникацию между средой (vci:Context в терминологии [9]) и нейроинтерфейсом (vci:Device). Посредник обладает собственным программным обеспечением, генерация которого производится автоматически под требуемые условия на основе управляющей онтологии. Также для генерации программного обеспечения будут необходимы онтология семантических фильтров [11], описывающая необходимые преобразования поступающих от нейроинтерфейса данных, и онтология компонент [12], предоставляющая исчерпывающее описание характеристик нейроинтерфейса (как программно-аппаратной системы).

Рис. 2 демонстрирует схему работы предлагаемого механизма интеграции. Здесь под vci:Device понимается собственно нейроинтерфейс, vci:Context описывает окружение, в которое будет производиться интеграция, VCI-O – основная управляющая онтология, mediator – непосредственно посредник, adapter – адаптер, реализующий механизм интеграции конкретного нейроинтерфейса в конкретной экосистеме IoT.

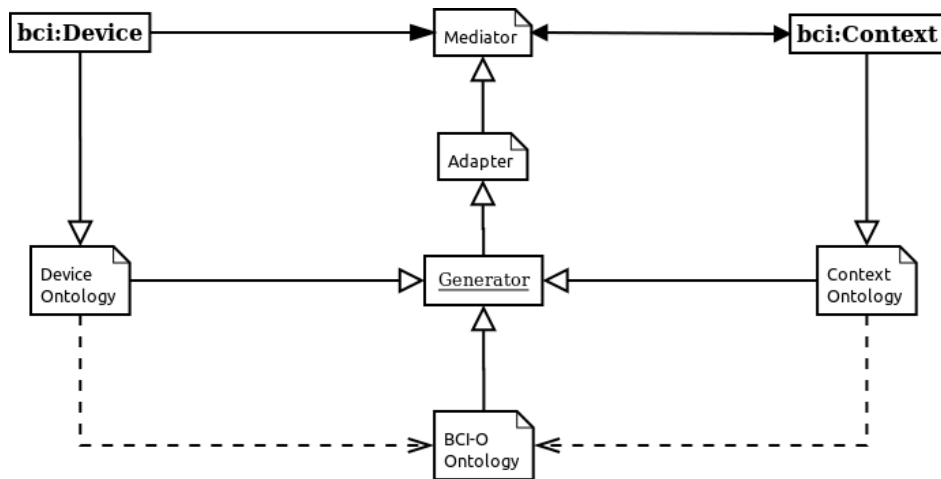


Рисунок 2. Схема работы предлагаемого механизма интеграции

Для интеграции нейроинтерфейса в имеющуюся IoT-инфраструктуру (например, экосистему «умного дома») необходимо выполнить следующие шаги (при описании шагов предлагаемого алгоритма везде, где упоминается создание онтологий, подразумевается возможность использования средств *ontology learning* для автоматизированного построения онтологий):

1. Взять из репозитория системы готовое, либо создать новое онтологическое описание конкретного нейроинтерфейса и его компонент, согласованное с онтологией BCI-O.

2. Взять готовое или создать новое онтологическое описание семантических фильтров для предобработки входных/промежуточных/выходных сигналов с целью их фильтрации в зависимости от условий решаемой задачи по аналогии с тем, как это реализовано в работе наших коллег, посвященных системе научной визуализации SciVi [13].

3. Взять из репозитория системы готовое, либо создать заново онтологическое описание конкретной экосистемы Интернета Вещей, согласованное с онтологиями BCI-O и IoT-O [14].

4. Использовать сервисы разрабатываемой авторами платформы под рабочим названием *MicroNeuroService* для автоматизированного построения адаптеров для нейроустройств и автоматической генерации на основе полученных онтологий микропрограмм, отвечающих за интеграцию нейроинтерфейса в инфраструктуру IoT.

Механизм онтологически управляемой генерации микропрограмм для Интернета Вещей ранее был разработан нашими коллегами в рамках работы над созданием и совершенствованием системой научной визуализации SciVi [13]. Аналогичные концепции мы используем применительно к решению задач интеграции нейроинтерфейсов в уже существующую, либо разрабатываемую с нуля экосистему Интернета Вещей.

Предлагаемое решение позволяет унифицировать процесс интеграции нейроинтерфейсов в конкретную экосистему Интернета Вещей. Построение онтологии, описывающей конкретный нейроинтерфейс, требуется выполнить

всего единожды, после чего оно пополняет соответствующий репозиторий онтологий и может быть многократно переиспользовано для автоматической регенерации микропрограмм посредников с целью интеграции с различными окружениями.

Заключение

В данной работе нами представлена концепция авторского подхода к разработке онтологически управляемых нейроинтерфейсов с целью их унифицированной интеграции в произвольную экосистему Интернета Вещей на основе механизма виртуальной интеграции. Дальнейшим направлением работы является завершение реализации и опытная эксплуатация механизма, обеспечивающего генерацию ПО посредника в нескольких вариантах: в виде ПО для компьютера, непосредственно взаимодействующего с нейроинтерфейсом; микропрограммы для нового устройства-посредника, интегрируемого в уже существующую экосистему Интернета Вещей; в виде отдельного модуля для встраивания непосредственно в сам нейроинтерфейс с целью его трансформации в edge-устройство категории Smart в инфраструктуре IoT. Исследования ведутся на базе беспроводной модульной переносимой системы для нейрофизиологических исследований класса BE Plus LTM (производство EB Neuro, Италия).

Библиографический список

1. Kothe, C. A. Introduction to BCI [Текст] / C. A. Kothe. – 09.08.2013. – URL: ftp://sccn.ucsd.edu/pub/bcilab/lectures/01_Introduction.pdf
2. Allison B. The I of BCIs: Next Generation Interfaces for Brain–Computer Interface Systems That Adapt to Individual Users // Human-Computer Interaction. Novel Interaction Methods and Techniques / под ред. J. A. Jacko. – Berlin, Heidelberg : Springer Berlin Heidelberg, 2009. – с. 558– 568. – ISBN 978-3-642-02577-8.
3. Huang S., Tognoli E. Brainware: Synergizing Software Systems and Neural Inputs // Companion Proceedings of the 36th International Conference on Software Engineering. – Hyderabad, India : Association for Computing Machinery, 2014. – с. 444–447. – (ICSE Companion 2014). – ISBN 9781450327688. – DOI: 10.1145/2591062.2591131. – URL: <https://doi.org/10.1145/2591062.2591131>.
4. Towards Standardized User and Application Interfaces for the Brain Computer Interface / P. McCullagh [и др.] // Universal Access in Human-Computer Interaction. Users Diversity / под ред. C. Stephanidis. – Berlin, Heidelberg : Springer Berlin Heidelberg, 2011. – с. 573–582. – ISBN 978-3-642-21663-3.
5. Workshops of the seventh international brain-computer interface meeting: not getting lost in translation / J. Huggins [и др.] // Brain-Computer Interfaces. – 2019. – дек. – с. 1–31. – DOI: 10.1080/2326263X.2019.1697163.
6. Ballard C., Davies N., Gavazzi M., et al. IBM Informix: Integration through data federation. // IBM Intern. Tech. Support Organizat. [электронный

- ресурс]. – 2008. – 270 р. – URL: <http://www.iiug.org/library/ids/technical/sg247032.pdf>.
7. Тузовский Анатолий Федорович, Ямпольский Владимир Захарович Интеграция информации с использованием технологий semantic web // Проблемы информатики. 2011. №2. URL: <https://cyberleninka.ru/article/n/integratsiya-informatsii-s-ispolzovaniem-tehnologiy-semantic-web> (дата обращения: 26.09.2020).
 8. Jose S., Mendez R. Modeling Actuators in BCI-O: A Context-Based Integration of SOSA and IoT-O // Proceedings of the 8th International Conference on the Internet of Things. – Santa Barbara, California, USA : Association for Computing Machinery, 2018. – (IOT '18). – ISBN 9781450365642. – DOI: 10.1145/3277593.3277914. – URL: <https://doi.org/10.1145/3277593.3277914>.
 9. Mendez S. J. R., Zao J. K. BCI Ontology: A Context-based Sense and Actuation Model for Brain-Computer Interactions // SSN@ISWC. – 2018.
 10. Ryabinin K., Chuprina S., Belousov K. Ontology-Driven Automation of IoT-Based Human-Machine Interfaces Development // Computational Science – ICCS 2019 / под ред. J. M. F. Rodrigues [и др.]. – Cham : Springer International Publishing, 2019. – с. 110–124. – ISBN 978-3-030-22750-0.
 11. Ryabinin K., Chuprina S. High-Level Toolset For Comprehensive Visual Data Analysis and Model Validation // Procedia Computer Science. – 2017. – т. 108. – с. 2090–2099. – ISSN 1877-0509. – DOI: <https://doi.org/10.1016/j.procs.2017.05.050>. – URL: <http://www.sciencedirect.com/science/article/pii/S1877050917305690> ; International Conference on Computational Science, ICCS 2017, 12-14 June 2017, Zurich, Switzerland.
 12. Ryabinin K., Chuprina S., Kolesnik M. Calibration and Monitoring of IoT Devices by Means of Embedded Scientific Visualization Tools // Computational Science – ICCS 2018 / под ред. Y. Shi [и др.]. – Cham : Springer International Publishing, 2018. – с. 655–668. – ISBN 978-3-319-93701-4.
 13. Рябинин К.В. Методы и средства разработки адаптивных мультиплатформенных систем визуализации научных экспериментов: автореф. дис. канд. физ.-мат. наук: 05.13.11. М., 2015. 23 с. URL: <http://library.keldysh.ru/avtoref.asp?id=2015-ryabinin>
 14. Seydoux, N., Drira, K., Hernandez, N., Monteil, T. IoT-O: a core-domain IoT ontology to represent connected devices networks. / под ред. Blomqvist, E., Ciancarini, P., Poggi, F., Vitali, F. // Knowledge Engineering and Knowledge Management, vol. 10024. – 2016. – с. 561–576. – URL: https://doi.org/10.1007/978-3-319-49004-5_36

CONCEPT OF ONTOLOGY-DRIVEN NEUROINTERFACE DEVELOPMENT

Labutin Ivan A., Chuprina Svetlana I.

Perm State University,

614990, Russia, Perm, st. Bukireva, 15, *barracuda72@bk.ru*

This paper presents the concept of an approach to ontology-driven neurointerfaces development allows to integrate them with any Internet of Things ecosystem in a unified way thanks virtual integration mechanism. An intermediate layer named mediator is introduced between the neurointerface and other components within IoT. The mediator uses the ontologies and provides integration according to the so-called federation model. We propose to use both the general methods and tools for ontology-driven solutions development, which already have been implemented within SciVi scientific visualization framework, and the new ones, which are developing now as a part of MicroNeuroService microservice platform. These new tools can be used as a separate software/hardware module within IoT as well as a software module on the side of the neurointerface, that enables to transform the existing neurodevices into Smart systems.

Key words: BCI, neural interface, ontological engineering.

УДК 378.146: 519.767

ИНТЕЛЛЕКТУАЛИЗАЦИЯ ТЕСТИРОВАНИЯ С ОТКРЫТЫМИ ВОПРОСАМИ НА ОСНОВЕ ОПРЕДЕЛЕНИЯ СЕМАНТИЧЕСКОЙ БЛИЗОСТИ ФРАЗ

Милов Владимир Ростиславович, Дубов Максим Сергеевич,

Калинина Наталья Андреевна, Салтыкова Анна Александровна

Нижегородский государственный технический университет

им. Р.Е. Алексеева, НГТУ. 603950, Россия, г. Нижний Новгород, ул. Минина,

24, *saltykova111@mail.ru*

В статье представлено описание системы открытого тестирования, основанной на процедуре автоматизированной оценки свободных ответов. На основе предложенных процедур определения семантической близости и автоматизированного оценивания свободных ответов разработан веб-сервис, внедренный и опробованный при проведения текущей и промежуточной аттестации студентов в рамках дистанционного обучения.

Ключевые слова: автоматизированное тестирование, открытые вопросы, семантическая близость, метод ближайших соседей, дистрибутивная семантика.

Системы тестирования с открытыми вопросами обладают преимуществами над традиционными системами тестирования, поскольку позволяют получать ответ испытуемого без предоставления ему какой-либо дополнительной информации за исключением текста самого вопроса. На сегодняшний день существуют системы тестирования, позволяющие испытуемым вводить в поля значения самостоятельно. Однако такие системы не обеспечивают автоматическую оценку уровня знаний в случаях, когда свободный ответ формулируется на естественном языке и состоит из одного или более предложений, а не отдельного слова.

Основными модулями разрабатываемой системы тестирования являются:

- модуль регистрации, осуществляющий регистрацию пользователей;
- модуль создания тестов, позволяющий добавлять вопросы в базу данных, одновременно группируя их в тесты;
- модуль тестирования, отбирающий и предъявляющий вопросы, а также принимающий ответы у тестируемых;
- поисковый модуль, выполняющий поиск по базе данных ранее сохраненных ответов;
- модуль оценки, позволяющий оценивать ответы тестируемых;
- модуль аналитики, позволяющий проводить статистическое исследование качества знаний испытуемых и учебных материалов.

Одним из важнейших блоков системы тестирования с открытыми вопросами является модуль определения семантической близости фраз. Такие модули могут применяться в автоматически проверяемых тестах для оценки уровня знаний терминов в изучаемой предметной области, что позволит снизить трудоемкость работы преподавателей и повысит качество проверки тестов.

Функционирование модуля оценки семантической близости фраз основано на вычислении меры семантической близости между ними. Мера семантической близости – это особая мера сходства фраз, предназначенная для количественной оценки семантической схожести, показывающая высокие значения для пар слов (фраз), находящихся в семантических отношениях (синонимия, гипонимия, ассоциативность), и малые значения для всех остальных пар. Меры семантической близости успешно применяются в различных задачах обработки естественного языка (NLP), таких как определение схожести текстов, расширение поисковых запросов, автоматические ответы на вопросы, снятие семантической неоднозначности слов и т.д.

Процедура определения семантической близости фраз получает на вход ответ тестируемого на вопрос, и ответы на тот же вопрос, хранящиеся в базе ответов, включая эталонные ответы. На выходе формируется оценка семантической близости введенного ответа пользователя к ответам, хранящимся в базе данных.

Семантическая близость между фразами вычисляется на основе предложенного обобщения коэффициента (бинарной меры сходства) Сёрренсена на случай нечетких множеств. Развиваемый подход базируется на известных технологиях NLP: векторных представлениях word2vec слов на естественном языке, косинусной мере их близости, семантических моделях русского языка RusVectores.

На основе вычисленных коэффициентов семантической близости между словами для сравниваемых предложений формируется матрица коэффициентов близости. Для выделения пар близких слов в сравниваемых предложениях поставлена разновидность задачи о назначениях. В результате максимизируется целевая функция, характеризующая семантическую близость предложений.

После вычисления всех коэффициентов близости и помещения их в буфер алгоритм проверяет достоверность полученных пар слов. Под недостоверностью понимается существенное (больше порогового) отличие коэффициентов достоверности. В случае если есть пары, не удовлетворяющие порогу, и их число больше заданного значения, то алгоритм останавливает свою работу с кодом выхода, запускающим процедуру отказа от принятия решения. На основе оценки вероятностей ошибок при условии принятия решения строится матрица ошибок (confusion matrix). В этом случае потребуется помощь эксперта для разметки новых для системы данных (ответа пользователя, для которого не нашлось в достаточной степени похожего варианта в базе данных).

Итоговая оценка близости анализируемого ответа и рассматриваемого на данной итерации ответа из базы осуществляется с помощью модифицированного алгоритма по методу k-ближайших соседей. В отличие от «классического» алгоритма находятся варианты ответов, близость которых к анализируемому ответу не меньше заданной. Пороговое значение для отбора соседей находится с помощью перекрестной проверки «с исключением по одному» (LOO-CV). Настройка процедуры (LOO CV) позволяет управлять порогом отказа от принятия решений.

При обработке ответов на вопрос об определении понятия «модель» выполняется оценка их семантической близости к ответам, содержащимися в базе. Так при анализе близости к эталонному ответу “Модель – системное отображение оригинала” фраза “Модель – упрощенное отображение объекта исследования” оценена как 65% а фраза “Модель – Это отображение каких-то определенных признаков оригинала которые необходимы для отображения и изучения в каких-либо условиях” – 46,1%. При этом экспертная оценка близости фраз также соответствует первому варианту.

Средневзвешенная оценка b_k эталонного ответа определяется как

$$\hat{b} = \sum_{k=1}^K w_k b_k$$

где w_k – весовой коэффициент, зависящий от нормированной

оценки семантической близости между \tilde{A} (ответ тестируемого) и A_k (множество эталонных ответов, хранящихся в базе $A_k, k = 1..K$).

Заключение. Описанная в статье система открытого тестирования позволяет не только снизить трудоемкость работы преподавателей и повысить качество проверки тестов, но дает дополнительные возможности для формирования и корректировки индивидуальных траекторий обучения, а также совершенствования учебных материалов. Указанный результат достигается за счет применения процедуры открытого тестирования, основанной на определении близости произвольных фраз, а также процедур корректировки индивидуальных траекторий обучения и обучающих материалов. Точность автоматизированного оценивания повышается по мере накопления базы ответов, оцененных экспертом. Таким образом, описанный подход актуален как для преподавателей, так и для обучающихся с целью снижения трудоемкости и повышения эффективности освоения материала. Разрабатываемая система открытого тестирования находит внедрение в учебный процесс на кафедре «Электроника и сети ЭВМ» Нижегородского государственного технического университета им. Р.Е. Алексеева.

INTELLECTUALIZATION OF TESTING KNOWLEDGE OPEN-ENDED QUESTION SYSTEM BASED ON SENTENCES SEMANTIC PROXIMITY CALCULATION

*Milov Vladimir R., Dubov Maxim S., Kalinina Natalia A., Saltykova Anna A.
Nizhny Novgorod State Technical University n.a. R.E. Alexeev
603950, Russia, Nizhny Novgorod, Str. Minin, 24, saltykova111@mail.ru*

The article describes a testing knowledge open-ended question system based on the automated evaluation of free answers. This web service is based on the proposed procedures for determining semantic proximity and automated assessment of free answers. It has been tested during the current and intermediate certification of students in the framework of distance learning.

Key words: automated testing, open-ended questions, semantic proximity, nearest neighbors' method, distributive semantics.

ПРИМЕНЕНИЕ САМООРГАНИЗУЮЩИХСЯ КАРТ КОХОНЕНА ДЛЯ АНАЛИЗА БАЗЫ ПАТЕНТОВ

Пастухова Галина Витальевна

Академическая школа информационных технологий при ПГНИУ, 614003,
Россия, г. Пермь, улица Чернышевского, д. 28, pastuhova13@email.ru

Рассматривается одна из технологий кластеризации – самоорганизующиеся сети Кохонена, проанализированы узкие места для анализа данных подобными алгоритмами. Затронуты общие проблемы адаптации математических моделей.

Ключевые слова: классификационный анализ, кластерный анализ, адаптация математических моделей

Основной метод классификационного анализа – это кластерный анализ, суть которого в разбиение множества исследуемых объектов и признаков на однородные в некотором смысле группы, называемые кластерами. Это многомерный статистический метод и исходные его данные могут быть значительного объема, т.е. существенно большим может быть как количество объектов исследования (наблюдений), так и признаков, характеризующих эти объекты. Помимо объёмности, эти данные зачастую являются «плохими», то есть природа их разнородности кроется не в невозможности или возможности разложения на кластеры, а в формировании (или нахождении) кластера или кластеров. Иначе говоря, это попытка разложить кубики по цвету при условии слепоты того, кто их раскладывает.

Также надо учитывать, что кластеры не что иное как группы однородности и задача кластерного анализа, на основании признаков объектов, разбить их множество на m (m – целое) кластеров так, чтобы каждый объект принадлежал только одной группе разбиения, что зачастую создает довольно таки жесткую модель, по ряду признаков «оторванную» от реальных объектов, чья сущность двулика, а порой и n -лика.

Объекты кластеризации представляются точками в n -мерном пространстве признаков (n – количество признаков, характеризующих объекты) и сходство между объектами определяется через понятие расстояния между точками, так как интуитивно понятно, что чем меньше расстояние между объектами, тем они более схожи.

Реализация кластерного анализа возможна посредством сетей (карт) Теуво Кохонена, семейства нейронных сетей без учителя. Самоорганизующаяся карта Кохонена – соревновательная нейронная сеть с обучением без учителя, выполняющая задачу визуализации и кластеризации.

Сущностно является методом проецирования многомерного пространства в пространство с более низкой размерностью.

Для обучения сети Кохонена используется соревновательный метод, где на каждом шаге обучения из исходного набора данных случайно выбирается один вектор. Далее производится поиск нейрона выходного слоя, для которого расстояние между его вектором весов и входным вектором – минимально.

По определённом правилу производится корректировка весов для нейрона-победителя и нейронов из его окрестности, которая задаётся соответствующей функцией окрестности. В данном случае в качестве функцией окрестности была использована функция Гаусса

$$h(u, c, t) = \exp\left(-\frac{\rho(c, u)}{\sigma(t)}\right)$$

где u – номер нейрона в двумерной решетке второго слоя сети, для которого вычисляем значение h , c – номер нейрона-победителя в двумерной решетке второго слоя сети, t – параметр времени.

Радиус окрестности h должен уменьшаться с увеличением параметра времени:

$$\sigma(t) = \frac{1}{\exp(t-2)}.$$

Для анализа базы патентов (база ФИПС) советского периода метод кластерного анализа посредством карт Кохонена был доработан, а именно, было введено понятие соседства не по метрике расстояния, а по ранжированию проекций векторов при уменьшении размерности.

Библиографический список

1. Кочин Н.Е. Векторное исчисление и начала тензорного исчисления. 9-е изд. М.: Наука, 1965.
2. Головки В.А., под ред. проф. А.И.Галушкина Нейронные сети: обучение, организация и применение. – Москва: ИПРЖР, 2001.
3. Энциклопедия информатиологии: учеб. пособие /авт. и сост. И.И. Юзвшин; под ред. А.М. Прохорова. М.: Информатиология, 2000.

**ЭКСПЕРТНАЯ СИСТЕМА
ДЛЯ АВТОМАТИЧЕСКОГО ВЫЯВЛЕНИЯ РОЛЕЙ
ПОЛЬЗОВАТЕЛЕЙ В СОЦИАЛЬНЫХ СЕТЯХ
НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ**

*Рабчевский Андрей Николаевич, Рабчевский Евгений Андреевич,
Заякин Виктор Сергеевич*
ООО «СЕУСЛАБ» 614066, Россия, г. Пермь, Шоссе Космонавтов 111 корп.3,
e.rabchevskiy@seuslab.ru

Ясницкий Леонид Нахимович
Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, yasn@psu.ru

В статье представлено описание разработки экспертной системы для автоматического выявления ролей пользователей в социальных сетях на базе нейронной сети. Нейронная сеть обучена на основе синтезированных множеств, содержащих ключевые характеристики ролей пользователей. Описан метод подготовки обучающих и тестовых множеств. Представлены результаты проектирования и обучения нейронной сети, проверки на адекватность и исследования предметной области.

Ключевые слова: искусственный интеллект, роль пользователя, социальная сеть, нейросеть, социально опасные явления и процессы.

Введение. Проблема определения ролей пользователей в социальных сетях имеет важное значение для целей предотвращения распространения в социальных сетях деструктивной информации и вовлечения пользователей социальных сетей в социально опасные явления и процессы.

Для определения уровня вовлеченности пользователей социальных сетей в социально опасные явления и процессы учитываются некоторые целевые индикаторы: количество постов, количество репостов, количество комментариев, количество лайков, участие в деструктивных группах и т.д.

Помимо указанных выше целевых индикаторов, необходимо также учитывать и социальную роль, которую играет каждый пользователь в том или ином социально опасном явлении или процессе.

Задача состоит в том, чтобы с помощью нейронной сети автоматически определять роль пользователя социальной сети в исследуемом социально опасном явлении или процессе на основе данных о пользователе, его социальных связях и паттернах активности.

Решение проблемы, как правило, имеет два аспекта: определение параметров классификации пользователей и выбор метода классификации

пользователей социальных сетей. Большинство таких методов так или иначе используют технологию искусственного интеллекта.

В одной из иностранных работ в качестве значимого параметра для определения потенциально эффективных распространителей информации в социальных сетях используется частота постов в социальной сети [1]. Другие исследователи используют K-means кластеризацию, основанную на рассмотрении похожих троек пользователей по их взаимодействию [2]. Встречаются также смешанные подходы, включающие кластеризацию с помощью трех алгоритмов (k-means, нейронная сеть SOM, DBSCAN) [3].

Все эти методы рассчитаны на глубокий анализ данных о пользователе, его окружении и паттернах его поведения, но требуют высоких затрат машинного времени и рассчитаны на обработку ограниченных объемов классифицируемых пользователей.

В то же время, в других предметных областях встречаются исследования возможности обучения нейронной сети с помощью данных, полученных в результате имитационного моделирования информационной системы [6].

В данном исследовании предлагается использование нейросетевой экспертной системы в качестве метода классификации пользователей социальных сетей и определения их социальных ролей.

В случае построения экспертной системы на базе нейронной сети необходимы обучающие и тестовые множества, полученные из предметной области. Разметка множеств выполняется экспертами на основе собственных знаний в данной предметной области. Часто получение таких множеств затруднено или связано с очень высокими затратами. В этом случае эксперты могли бы описать свои знания в виде совокупности параметров, описывающих объекты предметной области, и на основе этих параметров синтезировать множества для обучения и тестирования нейронной сети.

Именно такой подход предлагается использовать для классификации ролей пользователей социальных сетей.

В качестве входных данных используются сведения о пользователях, доступные в социальных сетях, которые могут существенно влиять на различие ролей пользователей. Перечень входных данных представлен в таблице 1.

Таблица 1 – Перечень входных данных

№	Показатель	Тип	Кодировка	Как влияет на результат	Метод получения
1	Возраст аккаунта	Непрерывный	Число	Чем старше аккаунт, тем может быть больше его влияние на других участников СС.	Вычисляется, как разница между текущей датой и датой регистрации аккаунта. Дата регистрации

№	Показатель	Тип	Кодировка	Как влияет на результат	Метод получения
					указана в персональных данных пользователя.
2	Возраст пользователя	Непрерывный	Число	Чем старше пользователь, тем более авторитетным может быть его мнение, и наоборот.	В персональных данных пользователя.
3	Кол-во друзей	Непрерывный	Число	Чем больше друзей, тем больше связей в СС.	В персональных данных пользователя.
4	Кол-во подписчиков	Непрерывный	Число	Чем больше подписчиков, тем большее влияние имеет на пользователей СС.	Вычисляется из списка подписчиков в персональных данных пользователя.
5	Кол-во подписок	Непрерывный	Число	Соотношение подписок и подписчиков может определять социальную роль пользователя.	Вычисляется из списка подписчиков в персональных данных пользователя.
6	Кол-во постов в месяц	Непрерывный	Число	Большое кол-во постов может свидетельствовать о том, что пользователь является источником идей или мнений.	Выборка в базе принадлеж. пользователю постов в регионе за месяц.
7	Кол-во репостов в месяц	Непрерывный	Число	Большое кол-во репостов говорит о том, что пользователь предпочитает транслировать и распространять чужое мнение. Соотношение постов и репостов показывает его социальную роль.	Выборка в базе принадлежащих пользователю репостов в регионе за месяц.
8	Кол-во комментариев в месяц	Непрерывный	Число	Показывает активность пользователя и	Выборка в базе принадлежащих пользователю

№	Показатель	Тип	Кодировка	Как влияет на результат	Метод получения
				характер его деятельности.	комментариев в регионе за месяц.
9	Кол-во лайков в месяц	Непрерывный	Число	Показывает активность пользователя и характер его деятельности.	Выборка в базе оставленных пользователем лайков в регионе за месяц.
10	Пол	Непрерывный	1=М, 2=Ж	Может иметь значение.	В персональных данных пользователя.
11	Время последнего нахождения в сети	Непрерывный	Число	Показывает актуальность пользователя.	В персональных данных пользователя.

Таким образом мы получаем 11 входных нейронов.

В качестве выходных нейронов используем социальные роли, указанные в таблице 2.

Таблица 2 – Социальные роли

№	Социальная роль
1	Лидер, генератор контента
2	Апостол, репостер, распространитель идей
3	Связной
4	Комментатор, тролль
5	Жертва
6	Бот

В результате получаем структуру персептрона, у которого 11 входных нейронов (X1–X11) и 6 выходных нейронов (Y1–Y6).

Структура векторов персептрона представлена ниже (**Ошибка! Источник ссылки не найден.**).

Таблица 3. – Структура векторов персептрона

X1	Возраст аккаунта	X10	Пол
X2	Возраст пользователя	X11	Время последнего нахождения в сети
X3	Количество друзей	D1	Лидер
X4	Количество подписчиков	D2	Репостер
X5	Количество подписок	D3	Связной
X6	Количество постов в месяц	D4	Тролль
X7	Количество репостов в месяц	D5	Жертва
X8	Количество комментариев в месяц	D6	Бот
X9	Количество лайков в месяц		

Параметры классификации, которые могли бы быть использованы экспертами при разметке множеств данных о реальных пользователях, представлены ниже (Таблица 3).

Таблица 3 – Возможные параметры классификации

№ Вх.	Наименование параметра	Лидер	Репостер	Связной	Троль	Жертва	Бот
X1	Возраст аккаунта, дней	300–3650	200–3650	200–3650	100–3650	1–350	1–100
X2	Возраст пользователя, лет	17–60	17–60	15–60	15–60	15–60	16–60
X3	Количество друзей	500–10000	150–10000	500–10000	100–10000	10–300	10–150
X4	Количество подписчиков	не менее 70 % от количества друзей	X3–X5	X3–X5	X3–X5	X3–X5	0–10
X5	Количество подписок	X3–X4	50–95 % от количества друзей	40–60 % для максимального кол-ва	6–100 % от количества друзей	40–95 % от количества друзей	10–100
X6	Количество постов	30–500	0–30	0–5	0–5	0–50	50–100
X7	Количество репостов	0–40 % от количества постов	150–600	30–150	30–100	0–50	50–300
X8	Количество комментариев	Не более 30 % от количества постов	0–30	0–15	100–1200	0–50	50–300
X9	Количество лайков	Не более 20 % от количества постов	0–30	0–15	0–15	0–50	100–1000
X10	Пол	случайно	случайно	случайно	случайно	случайно	случайно
X11	Время нахождения в сети, час	1–6	1–4	1–4	1–4	1–4	3–12

Проектирование нейронной сети выполнялось на основе устоявшейся методики [4]. Результат проектирования, обучения и оптимизации сети представлен на рис. 2.




Рисунок. 2. Структура нейросети.

1. Из представленной схемы видим, что достаточно одного промежуточного слоя. При этом, активационная функция на входном и промежуточном слое – тангенс гиперболический, а на выходном слое – линейная. Результаты обучения нейронной сети представлены на рисунке 3.

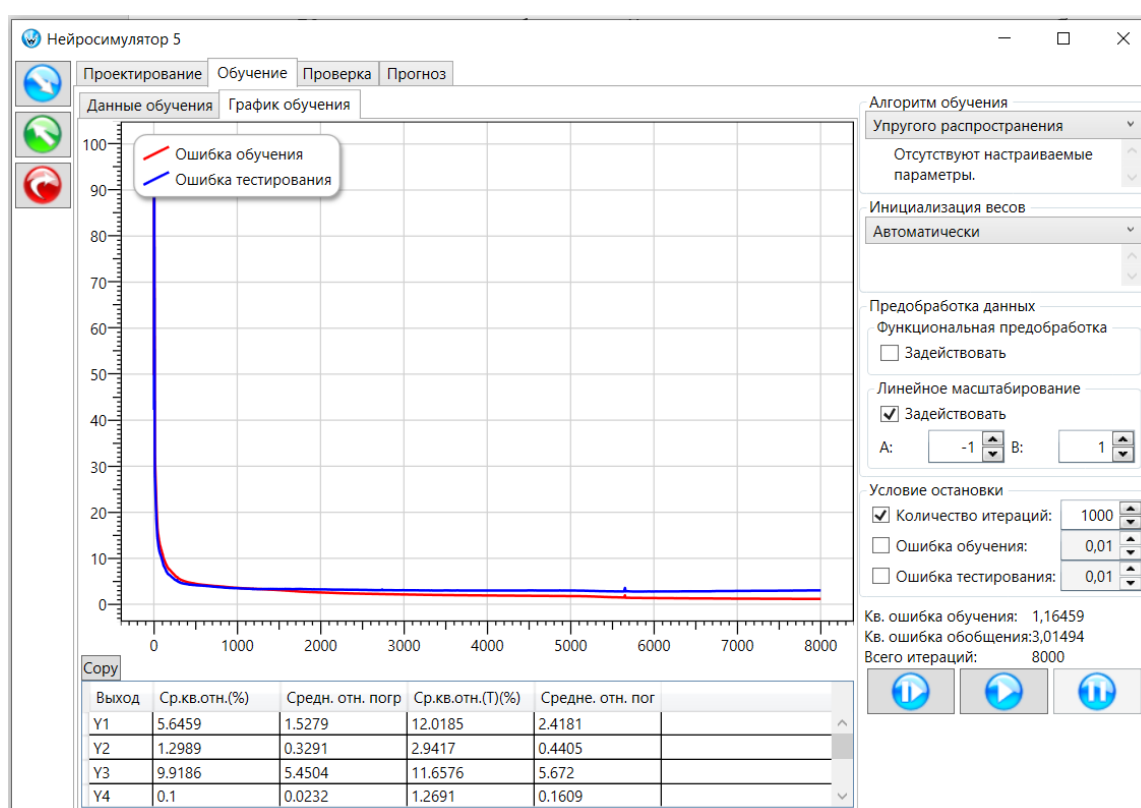


Рисунок. 3. График обучения нейросети.

Как видно из графика, нейронная сеть довольно хорошо обучилась. При этом, чем больше эпох обучения, тем меньше уровень погрешности обучения.

2. Сравнение ожидаемых показателей и результатов прогнозирования нейросети для роли «Лидер» (Y1), «Репостер» (Y2) и «Тролль» (Y4) представлено на рис. 4, 5 и 6.

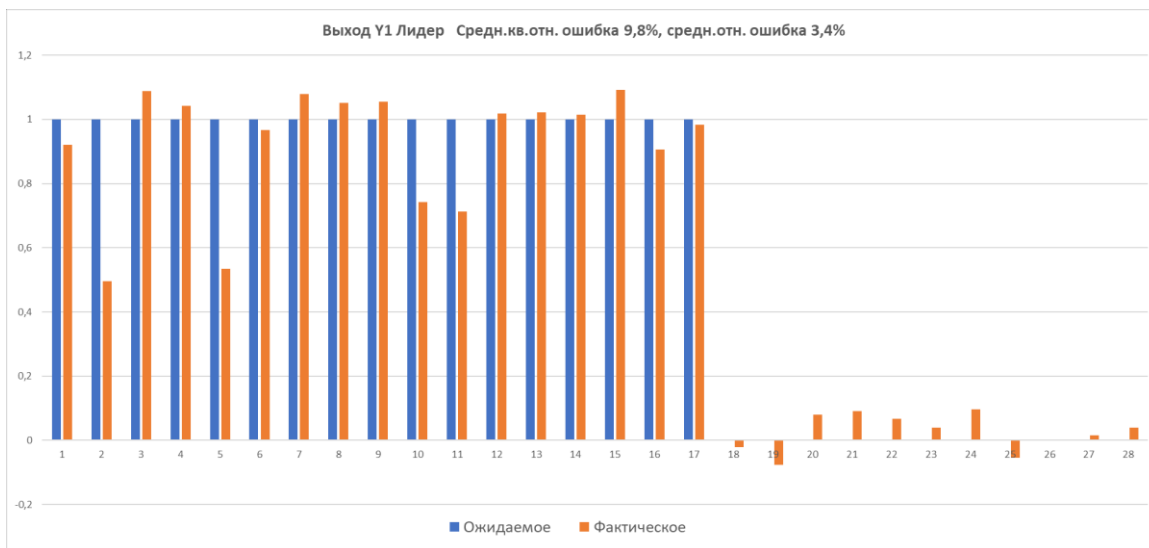


Рисунок 4. Результат проверки для роли Лидер (Y1)

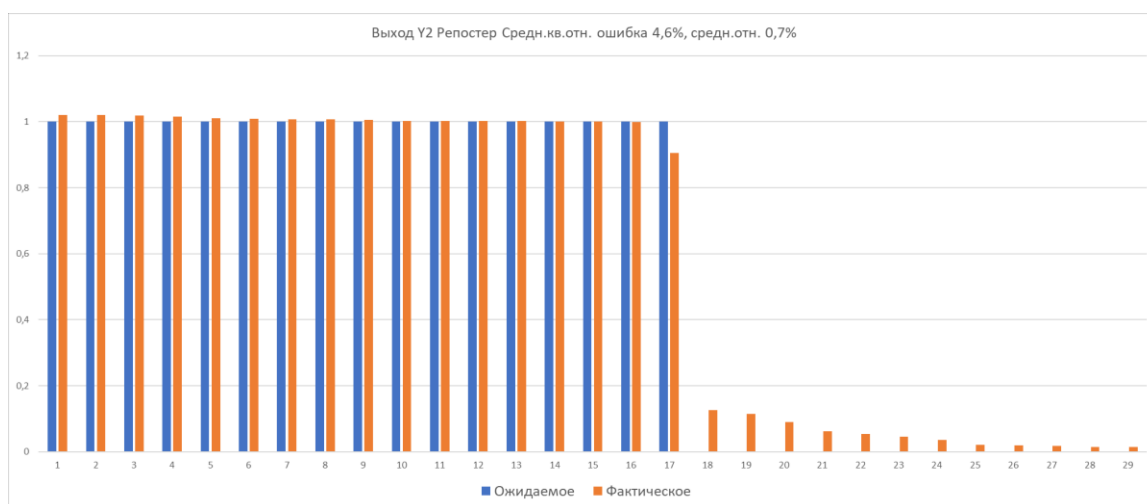


Рис. 5. Результат проверки для роли Репостер (Y2)




Рис. 6. Результат проверки для роли Троль (Y4)

График значимости параметров представлен на рис.7, из которого видно, что наиболее значимыми параметрами являются: количество комментариев, постов, репостов и количество друзей. Именно такие закономерности и были заложены в обучающее множество.




Рис. 7. График значимости параметров.

Для практического применения данного классификатора необходимо ввести данные реальных пользователей и сравнить результаты его работы с результатами экспертной оценки и результатов графового анализа, после чего скорректировать комбинации параметров в обучающих множествах на основании результатов такого сравнения.

Заключение. На основе анализа результатов проектирования и обучения нейронной сети можно сделать вывод, что нам удалось построить нейронную сеть, в которую заложены знания в виде обучающих множеств.

Фактически это экспертная система, в которую заложены знания эксперта о данной конкретной предметной области.

Изменяя параметры синтезированного обучающего множества, можно вносить в нейронную сеть знания о том, по каким признакам выявлять те или иные признаки пользователей социальной сети. Применение подобного метода не ограничивается только социальными сетями, это универсальный метод.

Предложенный метод классификации социальных ролей пользователей социальных сетей имеет важное практическое применение для решения задач общественной безопасности:

- Автоматическое выявление лидеров мнений и генераторов контента. Такие пользователи могут быть особенно интересны при анализе информационных атак или для влияния на аудиторию социальной сети.

- Автоматическое выявление распространителей информации в социальных сетях. Такие пользователи могут использоваться в качестве каналов информационного воздействия на социальные явления или противодействия информационным атакам.
- Автоматическое выявление ботов в сети. Это важно для выявления источника распространения «фейков», инструментов организованных воздействий на сеть, точек противодействия в сети и т.д.
- Автоматическое выявление структуры социальных сообществ с раскладкой по ролям в сообществе.
- Совместное использование предложенного классификатора и графового анализа дает новые возможности для быстрого поиска пользователей, относящихся к определенной социальной роли, анализа их социального окружения, выявления их социальных связей, установки их личностей для целей предотвращения противоправных действий, воздействия на социальную сеть или конкретное сообщество в сети.

Библиографический список

1. A. N. Arularasan, A. Suresh, K. Seerangan. IDENTIFICATION AND CLASSIFICATION OF BEST SPREADER IN THE DOMAIN OF INTEREST OVER THE SOCIAL NETWORK. (2018)
2. D. Doran. ON THE DISCOVERY OF SOCIAL ROLES IN LARGE SCALE SOCIAL SYSTEMS. (2015)
3. P. H. B. Ruas, A. D. Machado, M. C. Silva, M. R. G. Meireles, A. M. P. Cardoso, L. E. Zárate, C. N. Nobre. IDENTIFICATION AND CHARACTERIZATION OF FACEBOOK USER PROFILES CONSIDERING INTERACTION ASPECT. (2019)
4. Интеллектуальные системы [Электронный ресурс]: учебник / Л.Н. Ясницкий. – Эл. изд. – Электрон. текстовые дан. (1 файл PDF: 224 с.) – М.: Лаборатория знаний, 2016.
5. Сайт компании ООО «СЕУСЛАБ» [Электронный ресурс]. URL: <https://seuslab.ru/> (дата обращения: 29.10.2019)
6. Пятакович В. А., Василенко А. М., Мироненко М. В. Обучение нейронной сети как этап разработки экспертной системы для классификации источников физических полей при мониторинге акваторий // Вестник Инженерной школы Дальневосточного федерального университета. – 2017. – №. 3 (32). – С. 138-149.

EXPERT SYSTEM FOR AUTOMATIC IDENTIFICATION OF USERS ROLE IN SOCIAL NETWORKS ON THE BASIS OF NEURAL NETWORK TECHNOLOGIES

Rabchevskiy Andey N., Rabchevskiy Euvgen A., Zayakin V.
SEUSLAB Ltd., Cosmonaut Highway 111, b.3, Perm, Russia, 614066,
e.rabchevskiy@seuslab.ru

Yasnitsky Leonid N.
Perm state University, 15, Bukireva str., Perm, Russia, 614990, yasn@psu.ru

The article describes the development of an expert system for automatic identification of user roles in social networks based on a neural network. The neural network is trained on the basis of synthesized sets containing key characteristics of user roles. A method for preparing training and test sets is described. The results of neural network design and training, adequacy testing, and domain research are presented.

Key words: artificial intelligence, user role, social network, neural network, socially dangerous phenomena and processes.

UDC 004.89

ONTOLOGY REASONING ON MICROCONTROLLER UNITS

Ryabinin Konstantin
Perm State National Research University, 614990, Russia, Perm, Bukirev st., 15,
kostya.ryabinin@gmail.com

Evolving Ubiquitous Computing tends to push Artificial Intelligence to the edge of distributed networks, because it would bring more adaptivity whereby more flexibility and reliability to the Edge devices. But the computing resource constraints of the Edge devices hinder applying traditional Artificial Intelligence means, so the challenging task of creating compatible ones emerges. In this paper we address this challenge by proposing a new way to perform ontology reasoning on extremely resource-constrained devices. We developed and tested in practice the tiny ontology reasoner compatible with microcontrollers, as well as the concise binary representation combined with the cognitive compression algorithm to dramatically reduce the size of task ontologies and fit them in the Edge device memory. The proposed software means enable to use ontology-driven solutions within Edge Computing environment.

Key words: Ontology Engineering, Edge Computing, Microcontroller Units.

Fourth industrial revolution (also called “Industry 4.0”) brought concept of Ubiquitous Computing (UC) [1], introducing the new paradigm of integrating computational systems with the humans’ habitat. While this integration enables plenty of possibilities to increase the quality of human life, it appears a challenging task to maintain interoperability and context awareness of electronic devices, tackling both Machine-to-Machine (M2M) and Human-to-Machine (H2M) communication scenarios. Summarizing the technologies involved in UC, we came up with the following concise illustration of the main UC levels, see Fig. 1.

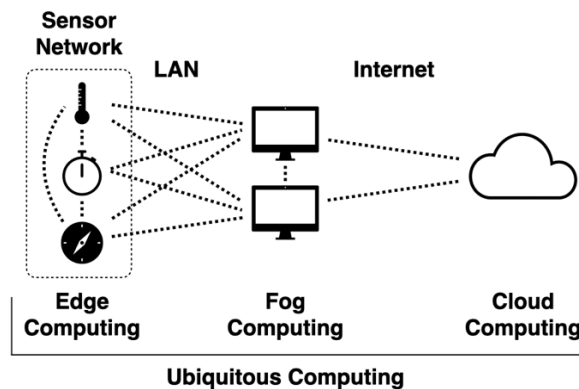


Fig. 1 Ubiquitous Computing levels

The topmost level of UC is Cloud Computing [2]. This level comprises high-performance computers often with Petaflops CPU and Terabytes of RAM. Traditionally, this level delivers data analysis and decision making based on Artificial Intelligence (AI), leveraging both Machine Learning (ML) technologies like Artificial Neural Networks and Cognitive Technologies like Semantic Web.

The next level of UC is Fog Computing [2] represented by hub computers with Megaflops of CPU and Gigabytes of RAM. Computing nodes of this level significantly vary in performance, starting by regular PCs and finishing by Systems on Chips (SoCs) like Raspberry Pi or Orange Pi. However, bringing AI to this level can be treated as a solved task. Modern ML algorithms as well as semantic technologies are capable of running on average home computers, which are in fact the core of Fog Computing.

The most lightweight level of UC lays on the edge of computing environment and consists of endpoint devices, for example sensors driven by microcontroller units (MCUs). This level is called Edge Computing [3], comprising local area sensor/actuator networks. The typical computing power on this level varies from case to case: the role of endpoint device can play relative performant SoCs (or sometimes even PCs), but also extremely resource-constrained MCUs. In the latter case, CPU frequency is measured in Kiloflops, and the memory units have only a few Kilobytes of capacity, or even less. This is why the traditional ways of AI functioning are often impossible to port to the Edge Computing devices. However, if nevertheless implemented, AI could bring Edge Computing to the new stage of organization, enabling adaptivity of individual devices and flexibility of the entire sensor/actuator network.

Edge Computing level is sometimes called the level of “smart things”. The word “smart” denotes the relation to the UC environment, where automated decision making is possible (often thanks to the Fog and Cloud levels). In this regard, AI on the Edge would significantly contribute to doing the “smart things” even smarter [4].

Regarding ML, there are successful attempts to enroll pre-trained (for example, on desktop computers) models on MCUs, to enable advanced pattern recognition and deliberate decision making [5]. While ML is normally all about approximation, which is useful for solving particular control tasks on the Edge, semantic technologies potentially allow to describe the tasks for solving and the ways to communicate ensuring thereby the intelligent context awareness for adaptivity and cooperation of Edge devices.

In the present work we address the challenge of pushing semantic technologies to the Edge of UC. In particular, we propose the methods and means to perform ontology reasoning on the MCUs, thereby achieving the ontology-driven Edge Computing [6].

The main obstacles for performing ontology reasoning on MCUs are insufficient RAM capacity, CPU frequency and power [7]. As these are in fact key characteristics of computer system, the one can assume MCUs to be inapplicable for ontology reasoning. Nevertheless, as seen in the literature, there were several attempts to marry ontology engineering methods and means with Edge devices. For example, Su et al. proposed special Entity Notation to store ontologies, ensuring 20 times knowledge compression compared to standard RDF notation [8]. This enables to define semantic protocols of Edge devices’ communication, but the full-fledged reasoning on the Edge is still impossible due to the lack of RAM. Sahlmann et al. proposed to utilize ontologies to describe Edge devices capabilities for advanced device virtualization [9]. Dibowski et al. proposed using ontologies to retrieve devices from the sensor network, select their operation mode and parametrize their functions [10]. However, these both researches assume reasoning on the Fog nodes, not on the Edge devices. Seitz et al. proposed ontology-based expert systems embedded on the Edge devices serving to detect failures within IoT ecosystem [7]. But the target devices are assumed to have several Megabytes of RAM, so MCU families like ATmega or ESP cannot handle this. Abdulrab et al. proposed so-called “ontology mediators” [11]: middleware that glues together different components of UC environment, including Edge devices. Ontology mediators help devices to communicate, as well as serve for aggregation and semantic filtering of data within UC ecosystem. But in this work only M2M scenario is considered.

Our goal was to consider both M2M and H2M scenarios addressing them within a unified approach to describing the entire Edge device behavior by task ontologies, which are interpreted in real time by the Edge device itself, without any help of Fog hubs. The distinctive feature of our research is the focus on MCU-based Edge devices (the ones driven, for example, by ESP8266, ATmega328 or even ATtiny45), which computing resources are extremely limited.

To achieve this goal, we developed the following software solutions:

1. Binary format called EON (stands for Embedded or Edge ONtology) to store ontologies in an extra concise form suitable for MCU memory.
2. “Cognitive compression” algorithm that allows to reduce the size of task ontology dramatically by trimming all the redundant information yet preserving the essential structure of task description and semantic power of ontology.
3. Software to generate configurable tiny reasoners capable of interpreting cognitively compressed ontologies stored in EON format. These reasoners are generated in C++ and play the role of MCU firmware, while the task ontologies are technically their input data.

The detailed description of technical details behind the EON format and cognitive compression algorithm is given in [6].

EON is chunk-based binary representation of task ontology attributes and relations. All entities are stored as tightly packed integer identifiers. Attributes may contain links to functions to be called and mathematical formulas to be calculated by MCU. Function links are stored as integer identifiers using lookup tables. Formulas are encoded using postfix notation. Constants in the formulas may be of different data types (numbers, strings, structures), being dynamically reinterpreted to the least sufficient type. That means, if the float number 1.0 appears, it is reinterpreted as 8 bit integer, while 1.1 is interpreted as 32 bit float (target data types are constrained to the ones natively supported by target MCUs to avoid the conversion burden).

Cognitive compression algorithm consists of the following main steps:

1. Remove the excessive ontology items (nodes and relations). Excessive items are identified as not directly related to the task being described, for example, the top-level prototype nodes and intermediate nodes, as well as their incident relations.
2. Apply the topological sorting for the remaining nodes.
3. Apply multilevel structure layout to the ontology to describe data flow chains in observable and concise form.

The indicated steps altogether ensure size reducing in more than 800 times compared to the standard OWL ontology representation. The above algorithm is implemented inside the ontology-driven platform SciVi (<http://scivi.tools>) [6]. This platform comprises different tools to automate data visualization and analytics, as well as generation of different software, including middleware and firmware for different UC use cases. One of the key features of SciVi is high-level ontology-driven editor based on data flow paradigm. This editor allows the user to describe data processing pipelines in an intuitive graphical form using just two types of entities: operator (data generator or processor) and data link. This kind of pipeline description is called data flow diagrams (DFDs). The example of DFD for gesture recognizing glove-style wearable Edge device is shown in the Fig. 2.




Fig. 2 Data flow diagram within SciVi

Building blocks the user can utilize by creating the particular DFD are described in the domain ontology of SciVi [12], so the set of available operators can be easily extended or modified according to the user's needs. In the Fig. 2 the building blocks related to the gesture detection are shown: MPU6050 (to access gyroscope and accelerometer sensor attached to the MCU), Digital Pin (to access the general-purpose input pin of the MCU), Mahony filter (to compose sensor orientation from the gyroscope and accelerometer data), Debounce filter (to remove the noise on the input pin), set of JSON encoders (to encode quaternion, Boolean value, and combine them into the solid JSON message) and WebSocket (to transmit the JSON message).

DFD composed by the user is automatically transformed by SciVi into corresponding task ontology that is being cognitively compressed, stored in the EON format and sent to MCU using some transmission line (currently WebSocket over WiFi for ESP8266 and I²C / SPI for other MCUs are supported).

However, the MCU should have appropriate firmware to be able to handle this ontology. Such a firmware is generated by SciVi as well, but this step is normally performed just once to prepare the MCU to be a part of ontology-driven Edge Computing ecosystem. All the upcoming upgrades of the MCU behavior are performed by changing its task ontology without touching its firmware.

The reasoner architecture is shown in the Fig. 3.

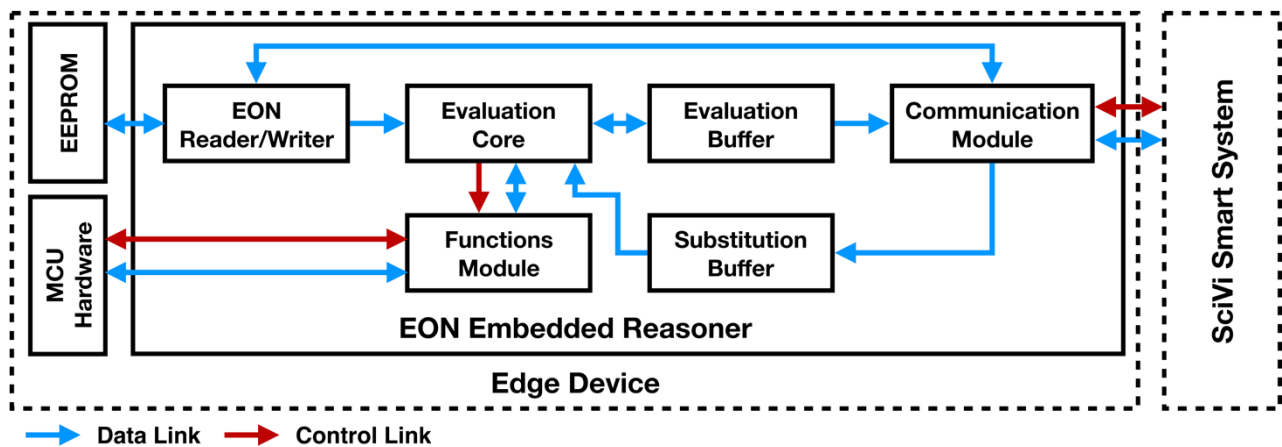


Fig. 3 Architecture of reasoner generated by SciVi to interpret EON-encoded ontologies on MCUs

Once generated and installed to MCU, the reasoner is able to communicate with SciVi via different communication standards (including WebSocket, I²C and SPI) using Communication Module to obtain ontologies and receive/transmit

supplementary data and AT-like control commands. Received ontology is stored in EEPROM of MCU using EON Writer and later extracted for reasoning using EON Reader. The Evaluation Core is responsible for the reasoning process storing the operational data in Evaluation Buffer. Communication Module makes these data accessible for SciVi for monitoring and debug purposes. To modify the reasoning results without modifying ontology (to debug the Edge device functioning or to execute one-time command) Substitution Buffer is used, which content can temporary replace the information from Evaluation Buffer. Both buffers are placed in the RAM of MCU. Functions described in the task ontology are executed by Functions Module that directly affects the MCU hardware. Functions Module is a variable part of the reasoner: the actual set of supported functions is chosen by user before the reasoner is generated. The restriction of functions set makes it possible to fit the reasoner into the constrained memory of MCU.

The proposed methods and software means were tested in practice by creating Smart Home automation IoT devices [6] and IoT-based hardware human-machine interfaces for solving visual analytics tasks [12]. The testing confirmed the following semantic features obtained by the Edge devices through the approach proposed: configuration transparency (it is very simple to reconfigure the device by uploading new task ontology, without changing the MCU firmware), context awareness (task ontology allows to describe both the task for the Edge device and the context of this task, as well as the rules of interoperation with other devices) and advanced monitoring capabilities (the reasoner can not only perform the tasks described by the ontology, but also stream intermediate reasoning results on demand).

Reference List

1. *Poslad S.* Ubiquitous Computing: Smart Devices, Environments and Interactions. John Wiley & Sons, Ltd. 2009.
2. *Pisani F., Borin E.* Fog vs. Cloud Computing: Should I Stay or Should I Go? // Proceedings of the Workshop on Intelligent Embedded Systems Architectures and Applications. 2018. P. 27–32. DOI: 10.1145/3285017.3285026.
3. *Hamilton E.* What is Edge Computing: The Network Edge Explained [Electronic source] URL: <https://www.cloudwards.net/what-is-edge-computing/> (retrieved: 02.09.2020).
4. *Malm J.* Edge AI for Techies – an Insight into Edge AI for the Tech Savvy Ones [Electronic source] URL: <https://www.imagimob.com/blog/edge-ai-for-techies> (retrieved: 02.09.2020).
5. *Szydło T., Sendorek J., Brzoza-Wońc R.* Enabling Machine Learning on Resource Constrained Devices by Source Code Generation of the Learned Models // Lecture Notes in Computer Science. 2018. Vol. 10861. P. 682–694. DOI: 10.1007/978-3-319-93701-4_54.
6. *Ryabinin K., Chuprina S.* Ontology-Driven Edge Computing // Lecture Notes in Computer Science. 2020. Vol. 12143. P. 312–325. DOI: 10.1007/978-3-030-50436-6_23.

7. *Seitz C., Schönfelder R.* Rule-based OWL Reasoning for specific Embedded Devices // *Lecture Notes in Computer Science*. 2011. Vol. 7032. P. 237–252. DOI: 10.1007/978-3-642-25093-4_16.
8. *Su X., Riekkı J., Haverinen J.* Entity Notation: Enabling Knowledge Representations for Resource-Constrained Sensors // *Personal and Ubiquitous Computing*. 2012. Vol. 16. P. 819–834. DOI: 10.1007/s00779-011-0453-6.
9. *Sahlmann K., Schwotzer T.* Ontology-Based Virtual IoT Devices for Edge Computing // *Proceedings of the 8th International Conference on the Internet of Things*. 2018. DOI: 10.1145/3277593.3277597.
10. *Dibowski H., Kabitzsch K.* Ontology-Based Device Descriptions and Device Repository for Building Automation Devices // *EURASIP Journal on Embedded Systems*. 2011. DOI: 10.1155/2011/623461.
11. *Abdulrab H., Babkin E., Kozyrev O.* Semantically Enriched Integration Framework for Ubiquitous Computing Environment // *Ubiquitous Computing*. 2011. P. 177–196. DOI: 10.5772/15262.
12. *Ryabinin K., Chuprina S., Belousov K.* Ontology-Driven Automation of IoT-Based Human-Machine Interfaces Development // *Lecture Notes in Computer Science*. 2019. Vol. 11540. P. 110–124. DOI: 10.1007/978-3-030-22750-0_9.

УДК 004.413

ОСОБЕННОСТИ ПРОЕКТИРОВАНИЯ СИСТЕМЫ КОНТРОЛЯ РЕГУЛЯРНЫХ РАСХОДОВ В МОБИЛЬНОМ ПРИЛОЖЕНИИ

Д.В. Титарев, канд. техн. наук, М.Н. Лисица, А.А. Анискин
Брянский государственный технический университет, titaryovdv@mail.ru

В статье описывается проектирование архитектуры и выбор средств разработки для системы, отвечающей за контроль регулярных расходов пользователя и их систематизацию. Описаны критерии выбора технологий и средств разработки для отдельных системных модулей. Описана модель системы, отражающая передачу данных между модулями системы. Рассматриваются четыре компонента системы: база данных, сервер, клиенты Android и iOS. Так же рассмотрена предметная область системы, отражающая существующие проблемы людей с регулярными расходами. Основная цель системы – это исключить у пользователей сервиса имеющиеся проблемы по контролю за своими регулярными тратами. Актуальность системы обусловлена тем, что большинство крупных организаций и сервисов внедряют свои продукты по подписке.

Ключевые слова: iOS; Android; регулярные расходы; напоминания; дизайн архитектуры; инструменты разработки; интегрированная среда разработки; сеть; база данных.

Введение

В современном мире человек все чаще сталкивается с необходимостью осуществления регулярных платежей. Если раньше это в большей части относилось к платежам в сфере ЖКХ, то сейчас, с развитием сетевых технологий люди активно используют различные подписки: музыкальные, видео и игровые сервисы, онлайн телевидение. Подписки входят и в автомобильную отрасль, компания BMW ввела доступ к функциям автомобиля через подписку. В связи с этим возникает задача планирования и контроля регулярных платежей, решение которой позволит избежать прерывания в использовании привычных сервисов, сократит издержки и необоснованные платежи.

Существует несколько подходов к учету регулярных расходов в личных целях. Самым распространённым является вариант, при котором человек запоминает свои регулярные платежи по памяти. В таком случае очень большая вероятность упустить из-под контроля ряд затрат, которые необходимо выполнить, т.к. при контроле необходимо учитывать: дату списания или оплаты, периодичность, сумму. Задача серьезно усложняется при росте количества регулярных платежей человека или наличии дополнительных условий.

Второй вариант контроля регулярных затрат – это запись на бумажном носителе перечня периодических платежей. Таким образом, человек избавляется от проблемы с параметрами регулярных затрат, но возникает потребность иметь всегда под рукой данный носитель, рассчитывать день следующей траты и контролировать изменения условия регулярной оплаты (сумму, дату платежа и т.д.).

Однако автоматизация данного процесса позволит избежать описанные выше проблемы, значительно сократить временные издержки на планирование и осуществление регулярных платежей.

Проектируемая программная система в виде мобильного приложения учитывает все недостатки описанных выше вариантов. Очевидным преимуществом является то, что мобильное устройство постоянно находится в близкой доступности для современного человека. Так же установленное на мобильное устройство приложение позволяет удобно добавлять в него свои регулярные расходы и минимизирует время на эти операции. После ввода всех регулярных расходов, человеку предоставляется полный контроль над перечнем его периодических затрат, с возможностью внесения необходимых изменений.

Но даже этой функциональности будет недостаточно, так как человеку потребуются постоянно заходить в мобильное приложение и проверять сроки исполнения регулярных расходов. Поэтому в проектирование программного комплекса была заложена функциональность с гибкой системой уведомлений

пользователя. Данная система позволит пользователю находиться в постоянной осведомленности путём получения уведомлений перед ближайшим регулярным платежом.

Таким образом, целью данной работы является проектирование и разработка универсального решения – системы контроля регулярных расходов, для сокращения затрат пользователя, а также изучение современных технологий для реализации данного решения. Наиболее важным аспектом в решении данной задачи является построение архитектуры системы и выделение необходимой функциональности для обеспечения максимального набора потребностей.

Модель системы

Проектируемая система должна предоставлять пользователю возможность централизованно собирать и хранить информацию о регулярных затратах и управлять ими (рис. 1).

$$M = \langle \Sigma, P, \zeta \rangle, \quad (1)$$

где на входе:

S – источник данных;

P – множество методов преппроессинга данных;

V – множество визуализаторов.

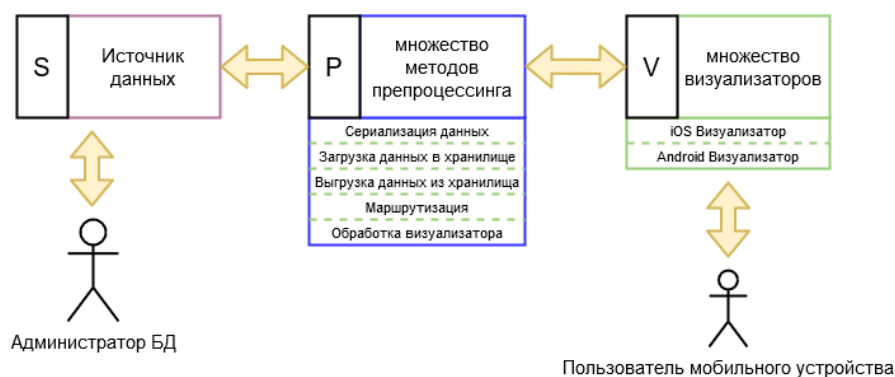


Рисунок 1. Общая модель системы

Множество методов преппроессинга данных можно представить в виде:

$$P = \langle P_s, P_m \rangle, \quad (2)$$

где P_s – множество методов преппроессинга данных сервера, а P_m – множество методов преппроессинга данных мобильного приложения.

В качестве метода преппроессинга данных сервера можно использовать: сериализацию данных, десериализацию данных, загрузку данных в хранилище, загрузку данных из хранилища, верификацию и маршрутизацию данных.

В качестве метода преппроессинга данных клиента можно использовать: сериализацию и десериализацию данных, загрузку данных в локальное хранилище данных, загрузку данных из локального хранилища, конвертацию данных.

Множество визуализаторов можно представить в виде:

$$\zeta = \langle \zeta_A, \zeta_I \rangle, \quad (3)$$

Где V_A – android-визуализатор, V_I – iOS-визуализатор.

Согласно разработанной модели данных, первоначальная загрузка и обработка хранимых данных (S) осуществляется с помощью множества методов препроцессинга данных сервера (P_s)[1]. После этого они передаются на обработку клиенту. Далее клиент производит вторичную обработку данных с использованием локального хранилища данных (P_m) и при необходимости возвращает данные обратно на сервер. Результат обработки данных представлен конечному пользователю с помощью множества визуализаторов (V).

Архитектура системы

В рамках выполнения данной работы была построена архитектура, включающая в себя три основных составляющих: клиент, сервер и база данных. Так же в ней было проведено исследование и анализ средств разработки, наиболее подходящих для реализации системы, учитывая специфику поставленных задач и описанных проблем.

При проектировании системы была составлена её архитектура (рис. 2) и выделены основные ее части: сервер, IOS-клиент, Android-клиент и база данных. Основным преимуществом архитектуры является универсальность, которая позволяет применять её к различным стекам технологий.

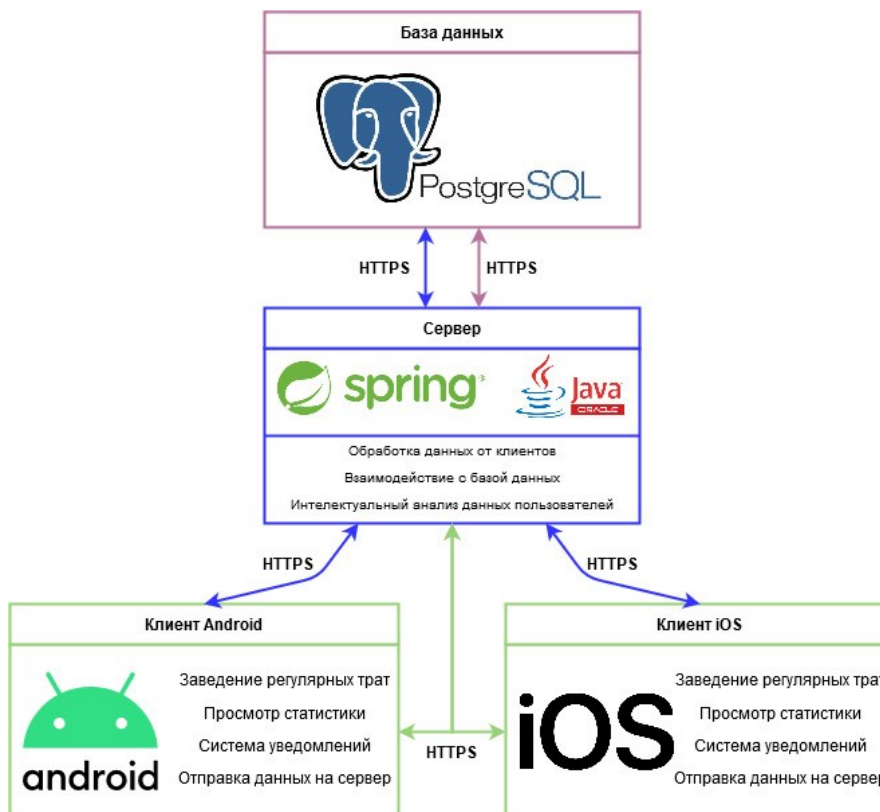


Рисунок 2. Общая архитектура системы

Клиент-серверная архитектура была выбрана, исходя из ее преимуществ:

- Безопасность. Все данные хранятся на сервере, обеспечивающим больший контроль безопасности, чем клиентские устройства.
- Централизованный доступ к данным. Поскольку данные хранятся только на сервере, администрирование доступа к данным намного проще, чем в любых других архитектурных стилях.

При этом сервер был организован с использованием паттерна MVC.

Так как одним из требований к системе является мобильность и модульность, то основной функционал модулей реализуется в виде библиотек. Таким образом, получается следующий набор библиотек для: взаимодействия с сервером, работы с json, взаимодействия с системами актуального курса валют, библиотеки для работы с локальной базой данных мобильного приложения.

Описание работы системы

При первом запуске пользователь заполняет список существующих регулярных трат и параллельно с этим устанавливается соединение с сервером. Соединение необходимо для оповещения системы о появлении пользователя в приложении.

При регистрации мобильное приложение посылает POST-запрос “device” к серверу. После этого сервер, возвращает статус запроса: «Устройство добавлено» – после получения статуса клиент продолжает свою работу.

Так же на сервере предусмотрена функциональность получения мобильным клиентом списка шаблонов регулярных затрат, которые позволяют пользователю ускорить процесс ввода своих периодических платежей в приложение. Данная функциональность предусматривает изменение порядка выдачи шаблонов регулярных затрат для пользователя, что позволит обеспечить удобную последовательность, исходя из профиля пользователя.

Кроме клиент-серверного взаимодействия важную роль играет разработка на мобильных клиентах системы гибких уведомлений пользователя о предстоящих регулярных платежах.

Локальные уведомления – это способ взаимодействия с пользователем в мобильном приложении[2]. Существуют так называемые Push-уведомления, которые отправляются непосредственно с сервера, в этом их главное отличие от локальных. Локальные уведомления создаются и отправляются с самого устройства.

Для работы с локальными уведомлениями в iOS-клиенте необходимо подключить фреймворк UserNotification[3]. При этом необходимо запросить у пользователя разрешения на отправку уведомлений с помощью метода `requestAuthorization` в ответе придет решение пользователя на получения уведомлений. Чтобы получить доступ к данному методу, можно использовать синглтон `UNNotificationCenter.current()`. Так как пользователь

может в любое время запретить получения уведомлений, существует метод для проверки текущего доступа `getNotificationSetting`.

Для создания регулярных уведомлений на iOS-клиенте необходимо использовать правильный набор компонентов даты[4], чтобы уведомление повторялось.

Заключение

В рамках работы были рассмотрены проблемы, возникающие контроле и управлении регулярными расходами: актуализация данных, своевременное исполнение, варианты контроля, передача на сервер и организация их централизованного хранения, кроссплатформенность и гибкая система уведомлений.

В настоящий момент времени на рынке существуют подобные решения, но они уступают спроектированному программному комплексу по ряду улучшающих вмешательств, позволяющих охватить больший спектр потребностей пользователя при работе со своими регулярными расходами. Улучшающими вмешательствами являются: гибкая система уведомлений, возможность семейного ведения регулярных платежей, модуль рекомендаций по набору регулярных трат.

Для комплексного решения данных проблем была решена задача проектирования и построения соответствующей архитектуры, а также выбора средств разработки информационной системы.

Разработанная система, архитектура которой описана в статье, позволяет контролировать пользователю регулярные расходы. Полученное решение является универсальным. Возможно его использование с комплексами, работающими с периодическими/регулярными данными пользователей, реализованными на различных платформах с использованием разнообразных средств разработки на собственных мобильных устройствах. Это приводит к сокращению временных затрат пользователя на контроль регулярных обязательств.

Библиографический список

1. Heckman R. (2016) The Data Abstraction Layer. Designing Platform Independent Mobile Apps and Services. Wiley-IEEE Press.
2. Local and Remote Notifications Overview [Электронный ресурс] – URL: <https://developer.apple.com/library/archive/documentation/NetworkingInternet/Conceptual/RemoteNotificationsPG/> (дата обращения 12.09.2020).
3. Local Notifications with Swift 4 [Электронный ресурс] – URL: <https://medium.com/quick-code/local-notifications-with-swift-4-b32e7ad93c2> (дата обращения 12.09.2020).
4. UserNotifications [Электронный ресурс] – URL: <https://developer.apple.com/documentation/usernotifications> (дата обращения 12.09.2020).

DESIGN OF INTEGRATED MOBILE APPLICATION SYSTEM FOR CONTROL RECURRING EXPENSES

D.V. Titarev, M.N. Lisitsa, A.A. Aniskin
Bryansk State Technical University

The article describes the design of the architecture and the choice of development tools for the system, which is responsible for the control of the user's regular expenses and their systematization. The criteria for choosing technologies and development tools for individual system modules are described. The system model is described, which reflects data transfer between system modules. Four system components are considered: database, server, Android client, and iOS client. The subject area of the system, reflecting the problems of people with regular expenses, is also considered. The main system is to exclude the users' goal of the service from the problem of controlling their regular spending. The relevance of the system is due to the fact that most organizations and services implement their products by subscription.

Key words: iOS; Android; regular expenses; reminders; architecture design; development tools; integrated development environment; net; database.

УДК 330.45

КОМПЬЮТЕРНАЯ ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ОПТИМИЗАЦИИ АДАПТИВНОГО УПРАВЛЕНИЯ ПРОЦЕССАМИ БИЗНЕС-ПЛАНИРОВАНИЯ¹⁷

Шориков Андрей Федорович

Уральский федеральный университет, 620002, Россия, г. Екатеринбург,
ул. Мира, 19, afshorikov@mail.ru

Буценко Елена Владимировна

Уральский государственный экономический университет, 620144, Россия,
г. Екатеринбург, ул. 8 Марта/Народной воли, 62/45, ev1@usue.ru

В статье представлена методика разработки интеллектуальной системы оптимизации адаптивного управления процессами бизнес-планирования в условиях неопределенности. Результаты работы базируются на новом методе оптимизации адаптивного управления проектами, использующем сетевое экономико-математическое моделирование. В статье описывается методика компьютерной реализации предлагаемой интеллектуальной системы, которая предназначена для автоматизации моделирования процессов бизнес-планирования и оптимизации адаптивного управления принятием решений

¹⁷ Публикация подготовлена при финансовой поддержке РФФИ (грант № 18-01-00544).
© Шориков А.Ф., Буценко Е.В., 2020

при их реализации на основе сетевого экономико-математического моделирования, а также методов и инструментария разработки интеллектуальных компьютерных систем. В разработанной системе учитываются имеющиеся конкретные технико-экономические условия и имеющееся информационное обеспечение. Полученные в работе результаты могут служить основой для создания интеллектуальных компьютерных систем поддержки принятия управленческих решений при осуществлении процессов бизнес-планирования в условиях информационной неопределенности.

Ключевые слова: интеллектуальная система, адаптивное управление, бизнес-планирование, оптимизация управления, экономико-математическое моделирование, сетевые методы планирования и управления.

Успешная деятельность любого предприятия требует создания современного инструментария для оптимизации управления реализацией процессов бизнес-планирования, соответствующих исходному бизнес-проекту, с учетом имеющихся технико-экономических и информационных условий, а также возникающих реальных производственных или организационных ситуаций. Для решения такой задачи предлагается технология разработки и создания интеллектуальной компьютерной системы оптимизации адаптивного управления процессами бизнес-планирования, базирующаяся на новом методе оптимизации адаптивного управления реализацией проектов [1], моделях и методах сетевого экономико-математического моделирования [1-3] и технологии разработки интеллектуальных систем в форме компьютерных экспертных систем поддержки принятия решений [4,5]. Для формализации знаний в данной системе предлагается использовать продукционные логические правила, алгоритмы в виде реализации конечных наборов арифметических и логических операций, которые устанавливают отношения между различными типами данных, стереотипными ситуациями и фактами с целью получения логических выводов и формирования результатов. При эксплуатации таких систем имеется возможность осуществлять обучение и накопление формализованной и неформализованной информации для применения в последующих процессах логического вывода и решения функциональных задач.

Предлагаемая интеллектуальная система разработана с использованием технологий компьютерных экспертных систем поддержки принятия решений [4,5]. В своем составе она имеет следующие подсистемы: базу данных, содержащую данные в различных форматах, структурированных в соответствии с архитектурой системы и функциональными задачами; базу знаний, содержащую факты и знания о моделях и методах бизнес-планирования, которые структурированы и формализованы различными средствами; подсистему приобретения знаний, использующую различные инструментальные средства; подсистему формирования решений функциональных задач системы (решателя задач), на основе реализации

различных механизмов, использующих процедуры логического вывода, формальные алгоритмы и эвристические процедуры, сопряженных с базой данных и базой знаний; подсистему объяснений (протоколирования) вывода решений; подсистему обучения; подсистему интеллектуального пользовательского интерфейса. На рис.1 представлена структурная схема предлагаемой компьютерной экспертной системы, содержащей основные подсистемы.

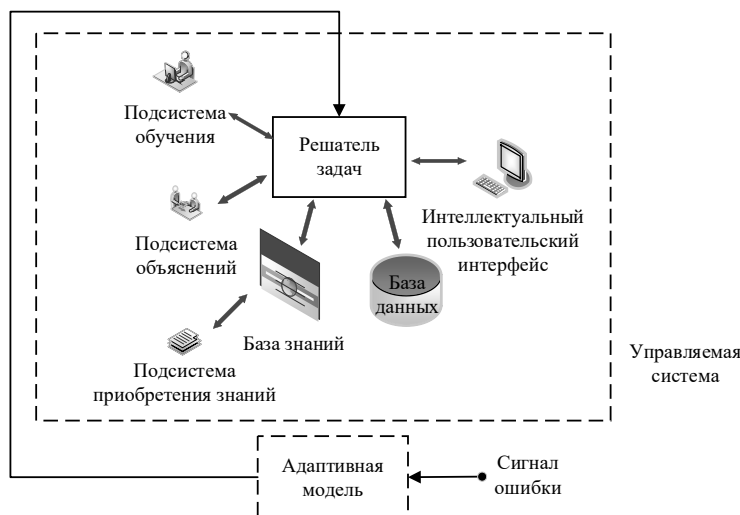


Рисунок. 1. Структура компьютерной интеллектуальной системы

Общая методика сетевого планирования и управления процессами бизнес-планирования для хозяйствующего субъекта (без возможности адаптации) приведена в монографии [2]. Новый метод решения задачи оптимизации адаптивного управления проектами на основе сетевого моделирования описан в работе [1]. В данной работе на основе этого метода разработана методика решения задачи оптимизации адаптивного управления процессами бизнес-планирования, которая реализована в предлагаемой интеллектуальной системе поддержки принятия решений.

В разработанной авторами компьютерной интеллектуальной системе Решатель задач содержит следующие основные блоки, реализующие процедуры формирования: 1) сетевой модели; 2) критического пути и критического времени; 3) позиции системы, описывающей текущее состояние процесса бизнес-планирования; 4) стратегии оптимального адаптивного управления процессом бизнес-планирования, как реакцию на сложившуюся позицию системы; 5) итоговых данных и отображения результатов решения задачи оптимизации адаптивного управления процессами бизнес-планирования.

В качестве тестовой задачи, в работе рассматривается применение предлагаемой методики оптимизации адаптивного управления процессами бизнес-планирования на примере реализации бизнес-проекта по открытию кафе.

Исходная информация для построения сетевой экономико-математической модели в виде основных работ-операций, необходимых для реализации бизнес-плана, соответствующего рассматриваемому бизнес-проекту, представлена в таблице.

Таблица 1 – Исходные данные бизнес-плана

№ работы	Содержание работы	Длительность работы, недель	Предшествующие работы
$R_1(0)$	Определение вида кафе	$\Delta_1(0)=1$	–
$R_2(0)$	Построение карты местности торговой территории	$\Delta_2(0)=2$	–
$R_3(0)$	Подбор шеф-повара	$\Delta_2(0)=2$	$R_1(0)$
$R_4(0)$	Разработка меню	$\Delta_3(0)=1$	$R_1(0), R_3(0)$
$R_5(0)$	Набор персонала	$\Delta_4(0)=2$	$R_3(0)$
$R_6(0)$	Оформление документов и проектной документации	$\Delta_5(0)=2$	$R_4(0)$
$R_7(0)$	Оформление и регистрация договора аренды	$\Delta_6(0)=2$	$R_1(0), R_2(0)$
$R_8(0)$	Выбор и покупка оборудования	$\Delta_7(0)=1$	$R_1(0), R_4(0)$
$R_9(0)$	Определение концепции продвижения	$\Delta_8(0)=1$	$R_1(0)$
$R_{10}(0)$	Формирование бюджета открытия кафе	$\Delta_9(0)=1$	$R_6(0), R_8(0)$

Сформированная сетевая модель бизнес-проекта в виде сетевого графика изображена на рис. 2. Начальным событием в этой сети является событие под номером 1, финальным – событие под номером 9. Символами $F_i(0), i \in \overline{1,5}$, отмечены фиктивные работы, не требующие затрат времени и ресурсов. В соответствии с методом оптимизации адаптивного управления проектами [1] разработана методика оптимизации адаптивного управления процессами бизнес-планирования, реализующими исходный бизнес-проект.

На первом этапе, вспомогательным параметрам $\tau := 0$ и $s := 0$, на основе исходных данных о рассматриваемых процессах бизнес-планирования и правил сетевого экономико-математического моделирования [2,3], формируется соответствующая сетевая модель реализации бизнес-планирования $WM_\tau^{(e)}(R(\tau)) = WM_0^{(e)}(R(0)) \in WM_0(R(0))$ в виде сетевого графика, которая изображена на рис. 2 и соответствует массиву работ-операций $R(\tau) = \{R_1(\tau), R_2(\tau), \dots, R_{n_\tau}(\tau)\} = R_\tau = R(0) = \{R_1(0), R_2(0), \dots, R_{10}(0)\} = R_0$, массиву

длительности исполнения работ-операций $\Delta(\tau) = \{\Delta_1(\tau), \Delta_2(\tau), \dots, \Delta_{n_\tau}(\tau)\} = \Delta_\tau = \Delta(0) = \{\Delta_1(0), \Delta_2(0), \dots, \Delta_{10}(0)\} = \Delta_0$.




Рисунок 2. Сетевая модель реализации процессов бизнес-планирования

На втором этапе, на основе исходных данных, включающих – начальный массив работ-операций $\mathbf{R}(\tau) = \{R_1(\tau), R_2(\tau), \dots, R_{n_\tau}(\tau)\} = \{R_1(0), R_2(0), \dots, R_{10}(0)\} = \mathbf{R}_0$, соответствующий ему массив длительности исполнения работ-операций $\Delta(\tau) = \{\Delta_1(\tau), \Delta_2(\tau), \dots, \Delta_{n_\tau}(\tau)\} = \{\Delta_1(0), \Delta_2(0), \dots, \Delta_{10}(0)\} = \Delta_0$, а также сформированную сетевую модель реализации процессов бизнес-планирования, необходимо оптимизировать сетевую модель по параметру времени – найти критический путь, критическое время и сформировать соответствующий календарный график реализации бизнес-планирования в целом, т.е. решить задачу календарного планирования [2,3].

Для данной сетевой модели, соответствующей рассматриваемому бизнес-проекту, критический путь представлен на рис. 3 и выделен серым цветом и жирной линией. Его длительность составляет 7 недель и состоит из набора работ-операций: $\{R_1(\tau), R_3(\tau), F_4(\tau), R_4(\tau), R_6(\tau), R_{10}(\tau)\} = \{R_1(0), R_3(0), F_4(0), R_4(0), R_6(0), R_{10}(0)\}$. В результате сформирован критический путь $\mathbf{R}^{(кр.)}(\tau) = \{R_1^{(кр.)}(\tau; \tau_1), R_2^{(кр.)}(\tau_1; \tau_2), \dots, R_{n_\tau}^{(кр.)}(\tau_{n_\tau}^{(кр.)-1}; \tau_{n_\tau}^{(кр.)})\} = \mathbf{R}_\tau^{(кр.)} = \{R_1^{(кр.)}(0;1), R_2^{(кр.)}(1;3), R_3^{(кр.)}(3;3), R_4^{(кр.)}(3;4), R_5^{(кр.)}(4;6), R_6^{(кр.)}(6;7)\} = \mathbf{R}^{(кр.)}(0) = \mathbf{R}_0^{(кр.)}$, где $n_\tau^{(кр.)} = 6$. Длительность реализации сформированного критического пути $\mathbf{R}_\tau^{(кр.)} = \mathbf{R}_0^{(кр.)}$ определяет критическое время $T_\tau^{(e)} = T_0^{(e)} = 7$, т.е. минимальное время, необходимое для выполнения всех работ-операций, образующих весь комплекс мероприятий для реализации процессов бизнес-планирования в целом.




Рисунок 3. Критический путь в сетевой модели реализации процессов бизнес-планирования ($\tau = 0$)

Для сформированной сетевой модели на основании найденного критического пути и соответствующего ему массива длительности исполнения работ-операций решается задача календарного планирования – формирования календарного графика в виде таблицы и диаграммы Ганта [2,3].

На третьем этапе, в соответствии с методом, описанным в [1], реализуется стратегия оптимизации адаптивного управления рассматриваемым процессом бизнес-планирования, т.е. формирования и реализации стратегии $U_a^{(e)} \in U_a$, где $U_a^{(e)} \in U_a$ – множество всех допустимых стратегий адаптивного управления [1]. Полученные результаты отображаются в форме, удобной для хозяйствующего субъекта (лица, принимающего решения), реализующего процесс оптимизации адаптивного управления бизнес-планированием, в виде таблиц, графиков и диаграмм.

Отметим, что применение метода оптимизации адаптивного управления процессами бизнес-планирования при разработке предлагаемой компьютерной интеллектуальной системы позволяет осуществить обратную связь в форме соответствующих реакций управляющего воздействия на непредвиденные изменения ситуаций при его реализации и получить оптимальный результат – оптимальное время для исполнения бизнес-проекта в целом.

Реализация процессов бизнес-планирования является важным элементом деятельности любого финансово-хозяйственного объекта и для решения возникающих при этом сложных задач необходима разработка экономико-математических моделей и методов их решения, а также создание на их основе программных комплексов, автоматизирующих базовые функции и поддержку принятия управленческих решений. В данной статье представлено описание разработанной авторами компьютерной интеллектуальной системы, реализующей оптимизацию адаптивного управления процессами бизнес-планирования на основе нового метода, использующего сетевое моделирование и технологии компьютерных экспертных систем. Предлагаемая интеллектуальная система реализована в

среде Delphi в виде web-приложения и удобна в качестве инструментария для поддержки принятия решений при реализации процессов сетевого моделирования и бизнес-планирования. Внедрение данной компьютерной интеллектуальной системы хозяйствующими субъектами в практику своей работы позволит им повысить эффективность процессов формирования и реализации бизнес-проектов. Эта система может также использоваться для экспертизы качества разработанных бизнес-проектов и тренинга.

Библиографический список

1. Шориков А.Ф. Сетевая экономико-математическая модель адаптивного управления проектами // Анализ, моделирование, управление, развитие социально-экономических систем: сборник материалов XIII Междунар. школы-симпозиума АМУР-2019 / Под общей редакцией А.В. Сигала. ISBN 978-5-6042038-4-2. – Симферополь: Изд-во КФУ; ИП Корниенко А.А, 2019. С. 425-428. <https://www.elibrary.ru/item.asp?id=41189303>
2. Шориков А.Ф., Буценко Е.В. Прогнозирование и оптимизация результата управления инвестиционным проектированием. М.: URSS-ЛЕНАНД, 2017. 272 с.
3. Таха Хемди А. Введение в исследование операций, 7-е издание: Пер. с англ. М.: Издательский дом «Вильямс», 2005. 912 с.
4. Марселлус Д. Программирование экспертных систем на турбо-прологе: пер. с англ. – М.: Финансы и статистика, 1994. – 256 с.
5. Aksyonov K., Vykov E., Aksyonova O., Goncharova N., Nevolina A. Application of the Hybrid Agents Technology for Control of the Construction Company // Proceedings of the International Conference on Computer Science and Applications 2016 (ICCSA 2016) part of the World Congress on Engineering and Computer Science 2016, WCECS 2016, October 19-21, 2016, San Francisco, USA. Vol.I. P. 159-164.

COMPUTER INTELLECTUAL SYSTEM OF OPTIMIZATION OF ADAPTIVE CONTROL OF BUSINESS PLANNING PROCESSES

Shorikov Andrey F.

Ural Federal University, 19, Mira str., Ekaterinburg, Russia, 620002,
afshorikov@mail.ru

Butsenko Elena V.

Ural State University of Economics, 62/45, 8 Marta st/Narodnoy voli st,
Ekaterinburg, Russia, 620144, evl@usue.ru

The article presents a methodology for developing an intelligent system for optimizing adaptive control of business planning processes in the face of uncertainty. The results are based on a new method for optimizing adaptive project control using network economic and mathematical modeling. The article describes the methodology of computer implementation of the proposed intellectual system,

which is intended to automate the modeling of business planning processes and optimize adaptive decision-making management when they are implemented based on network economic and mathematical modeling, as well as methods and tools for developing intelligent computer systems. The developed system takes into account the existing specific technical and economic conditions and the available information support. The results obtained in this work can serve as the basis for creating intelligent computer systems for supporting managerial decision-making in the implementation of business planning processes in the conditions of information uncertainty.

Key words: intelligent system, adaptive control, business planning, optimization of control, economic and mathematical modeling, network planning and control methods.

УДК 004.93'12

СИСТЕМА РАСПОЗНАВАНИЯ ЛИЦ ДЛЯ СЕРВИСНОГО РОБОТА

Льонгрин Андрей Константинович
Детский технопарк Кванториму Фотоника г. Пермь,
iam.prostoi.chelovek@gmail.com

Курушин Даниил Сергеевич
Детский технопарк Кванторим Фотоника г. Пермь, dan973@yandex.ru

Лицо является важнейшим средством невербальной коммуникации. Из лица можно извлечь огромный объем информации: пол, возраст, национальность; уникальные черты лица позволяют точно идентифицировать человека, а мимика и направление взгляда позволяют понять эмоцию и объект речи, что особенно полезно при ведении диалога [1]. Поэтому, система распознавания лиц является одной из главных для сервисного робота (как для любого другого робота, взаимодействующего с людьми).

Целью проекта является создание модульной системы распознавания лиц¹⁹, способной работать в реальном времени, с высокой точностью, и максимальной стабильностью.

Ключевые слова: распознавание лиц, локализация лиц, идентификация лиц, нормализация лиц OpenCV, dlib, c++.

Алгоритмы

Распознавание лица – комплексный процесс, состоящий из нескольких этапов, зависящих от конкретной задачи. Наша система включает в себя следующие: локализация, нормализация, отслеживание, идентификация, (в

© Льонгрин А.К., Курушин Д.С., 2020

¹⁹ Под термином “распознавания лиц” подразумевается более широкая область, нежели “идентификация по лицу” – получение любой информации о человеке по изображению его лица.

разработке:) распознавание пола, возраста, национальности, локализация отдельных регионов лица (глаза, нос, и т.п.), определение направления взгляда. Рассмотрим каждый этап более подробно...

Локализация

В данный момент в программе реализована локализация лиц с использованием пре-обученной сверточной нейронной сети, идущей в составе [2] библиотеки OpenCV, основанной на архитектурах ResNet-10 [3] и SSD [4]. Эта нейросеть дает высокое, и что важно, стабильное качество локализации, она способна распознавать лица, перекрытые более чем на 60% или наклоненные на угол свыше 45°, что является отличным результатом, но к сожалению, качество локализации может резко падать для определенных лиц или условий окружения. Это является большой проблемой для сервисного робота, т.к. он должен быть способен оперировать различных непредсказуемых условиях и взаимодействовать с разными людьми.

В качестве альтернативы, планируется добавить поддержку для моделей, основанных на архитектуру MTCNN [5] – MultiTask ConvolutionalNeuralNetwork. Преимуществом данной архитектуры является многоступенчатый подход к локализации, который дает возможность значительно улучшить качество за счет большей специализации каждой из трех использованных нейросетей. Также, такая архитектура позволяет выполнять нахождение ключевых точек лица одновременно с локализацией, что может увеличить производительность всей системы.

Нормализация

Этап нормализации важен для всех последующих этапов распознавания, и в особенности для идентификации. Несмотря на то, что современные алгоритмы стремятся минимизировать зависимость от таких параметров, как наклон лица, тени и вариация освещения, предварительная нормализация (приведение этих параметров к определенному фиксированному значению) способна значительно улучшить точность их работы и уменьшить количество обучающих примеров.

В текущей версии, реализован простейший вариант нормализации – выравнивание лица по ключевым точкам. Как понятно из определения, она состоит из двух этапов: нахождение ключевых точек и выравнивание лица по ним. Для нахождения ключевых точек используется готовая модель, идущая в составе [6] библиотеки Dlib, которая определяет 5 ключевых точек лица. Этого вполне достаточно для успешного выравнивания, и более того, меньшее количество ключевых точек минимизирует ошибку при сильном искажении или перекрытии лица (по сравнению, например, с моделью, распознающей 68 точек). Процесс выравнивания сводится к выполнению аффинного преобразования [7] таким образом, что распознанные точки лица перемещаются в позиции, заданные шаблоном. Главное преимущество такого метода в его скорости, т.к. нахождение ключевых точек (в данной реализации), как и аффинные преобразования являются достаточно дешевыми операциями. Минусом-же является относительно низкая стабильность работы, а также плохое качество выравнивания сильно наклоненных лиц.

Планируется также изучить другие подходы к выравниванию лиц, полностью основанные на нейронных сетях [8], или использующие другие методы выравнивания ключевых точек [9]. Также, в будущем будет добавлена дополнительная стадия нормализации – выравнивание цвета и удаление теней, но это достаточно сложная и обширная тема, а также имеется риск исказить оригинальную структуру лица, поэтому, мы отложили эту задачу.

Отслеживание

Этап отслеживания необходим для сопоставления лиц на предыдущем кадре лицам на текущем. Это нужно для двух целей: отслеживание нераспознанных лиц, для последующего внесения их в базу, и для оптимизации работы модуля идентификации – идентификация может быть выполнена единожды, а затем, распознанный ID лица будет сохранен, и выполнять идентификацию не потребуется.

Сейчас, в программе реализован простейший метод отслеживания с сопоставлением лиц на кадрах по расстоянию между их центральными точками. Плюс данного подхода – это его простота реализации и высокая скорость работы. Минус его заключается в высокой вероятности ошибки сопоставления при близком расположении лиц, или при их быстром движении.

Для более эффективного отслеживания решено было выбрать алгоритмы с использованием фильтра Калмана [10]. Предварительно изучив сравнительные анализы разных алгоритмов [11], мы планируем добавить поддержку алгоритма Адаптивного фильтра Калмана с усредненным сдвигом [12], т.к. он показал наилучшие результаты в приведенном выше исследовании. Также, использование алгоритмов, основанных на фильтре Калмана позволит реализовать более сложный сценарий отслеживания – предсказание позиции лица на следующем кадре, без необходимости выполнения локализации, что поможет значительно ускорить работу программы.

Идентификация

Идентификация является неотъемлемой частью любой системы распознавания лиц. Идентификация позволяет персонально подстраивать стиль общения под каждого человека, а также собирать информацию и даёт возможность реализовывать такие функции, как например создание напоминаний, или охранный режим.

Для идентификации существует множество подходов, но нами был выбран вариант с использованием так называемых дескрипторов лица. Он состоит из двух этапов: нахождение уникального вектора признаков (дескрипторов) лица, и их классификация.

Вычисление дескрипторов реализовано с использованием нейронной сети модифицированной архитектуры [13] ResNet-34 [3], идущей в составе библиотеки Dlib, которая генерирует вектор из 128 дескрипторов. Эта модель показывает неплохой результат, при небольшом (до пяти) количестве лиц, но качество может ухудшаться с увеличением их числа. Для улучшения качества работы с большим количеством лиц планируется найти модель, с

более высоким количеством дескрипторов, а также, до-обучить ее на примерах лиц, полученных на предыдущих стадиях конкретной этой системы.

На втором этапе, полученные дескрипторы классифицируются с использованием One-vs-One SVM классификатора [14]. Данный подход также имеет недостаток в виде уменьшения качества классификации с ростом количества объектов, поэтому мы также планируем изучить эту тему глубже, и протестировать различные классификаторы, такие как алгоритм К-ближайших соседей [15], или вариант использования неглубокой нейронной сети, например, однослойный персептрон [16].

Программная реализация

Система написана на языке программирования C++ с использованием таких библиотек компьютерного зрения и машинного обучения, как OpenCV 4 [17] и Dlib [18]; в качестве системы сборки использовался CMake. Исходный код проекта можно найти на GitHub [19].

Основной целью при разработки данной системы была модульность и простота дополнения и проведения экспериментов. Каждый этап распознавания описанный выше выделен в отдельный модуль. Каждый модуль реализует программный интерфейс, описанный в нём, что позволяет использовать принципы полиморфизма, и легко заменять разные реализации одного этапа.

В процессе проектирования была выявлена необходимость реализации абстрактной фабрики [20], которая еще более упрощает замену разных реализаций интерфейса. На рис. 2 показан пример инициализации компонентов, с использованием метода фабрики: первый параметр – имя модуля (его главного интерфейса), второй – имя реализации, все последующие параметры будут переданы в конструктор создаваемого класса.

Также, для достижения еще большей гибкости системы, планируется реализовать вариацию паттерна Pipeline [21]. Это позволит динамически изменять процесс обработки, а также, упростит распределение и распараллеливание системы, что положительно скажется на производительности.




Рисунок. 1 Пример работы системы

Заключение

Несмотря на то, что существует огромное множество подобных систем, мы считаем, что реализация собственной вариации имеет практический смысл: это позволяет нам иметь полный контроль над всеми этапами работы, легко вносить изменения и добавлять новые модули, уменьшает порог входа в проект, и главное – позволяет изучить весь широкий спектр технологий и алгоритмов связанных с распознаванием лиц (и с компьютерным зрением в целом) на практике, что очень ценно.

Нам удалось построить программную соответствующую всем изначальным требованиям, что значительно упростит разработку новых модулей и сможет окупить большие временные затраты на ее проектирование и написание.

Реализация системы распознавания лиц является важным этапом создания нашего более крупного проекта – человекоподобного робота ассистента. Поэтому, мы планируем закончить работу над проектом, и реализовать все вышеописанные улучшения.

Библиографический список

1. Rachael E. Jack, Philippe G. Schyns The Human Face as a Dynamic Tool for Social Communication // ScienceDirect. 2015. №25.
2. how_to_train_face_detector.txt // github.com URL: https://github.com/opencv/opencv/blob/master/samples/dnn/face_detector/how_to_train_face_detector.txt
3. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun Deep Residual Learning for Image Recognition // IEEE CVPR. 2016.90.
4. Liu W. et al. SSD: Single Shot MultiBox Detector // Lecture Notes in Computer Science. 2016. №9905.
5. Kaipeng Zhang, Zhanpeng Zhang, Zhifeng Li, Yu Qiao Joint Face Detection and Alignment using Multi-task Cascaded Convolutional Networks // IEEE Signal Processing Letters . 2016. №23.
6. shape_predictor_5_face_landmarks.dat.bz2 // github.com URL: https://github.com/davisking/dlib-models#shape_predictor_5_face_landmarksdatbz2
7. Affine transformation // Wikipedia.org URL: https://en.wikipedia.org/wiki/Affine_transformation
8. Y. Qian, W. Deng, J. Hu Unsupervised Face Normalization With Extreme Pose and Expression in the Wild // IEEE CVPR. 2019.
9. Master Prince A Simple Method for Face Normalization Based on Novel Normal Facial Diagram // International Journal of Video&Image Processing and Network Security. 2013. №13.
10. Фильтр Калмана // Wikipedia.org URL: <https://bit.ly/2RjvIJJ>
11. Vaibhav Kumar Agarwal, N. Sivakumaran, V. P. S. Naidu Six Object Tracking Algorithms: A Comparative Study // Indian Journal of Science and Technology. 2016. №9.

12. Karavasilis V., Nikou C., Likas A Visual Tracking by Adaptive Kalman Filtering and Mean Shift // Lecture Notes in Computer Science. 2010. №6040.
13. `dnn_face_recognition_ex.cpp` // `dlib.net` URL: http://dlib.net/dnn_face_recognition_ex.cpp.html
14. One-vs-Rest and One-vs-One for Multi-Class Classification // `machinelearningmastery.com` URL: <https://machinelearningmastery.com/one-vs-rest-and-one-vs-one-for-multi-class-classification/>
15. k-nearest neighbors algorithm // `Wikipedia.org` URL: https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm
16. Перцептрон // `Wikipedia.org` URL: <https://bit.ly/3bPooix>
17. OpenCV website // `opencv.org` URL: <https://opencv.org/opencv-4-0/>
18. Dlib website // `dlib.net` URL: <http://dlib.net/>
19. `faceDetector` // `github.com` URL: <https://github.com/prostoiChelovek/faceDetector>
20. Abstract factory pattern // `wikipedia.org` URL: https://en.wikipedia.org/wiki/Abstract_factory_pattern
21. Pipeline (software) // `wikipedia.org` URL: [https://en.wikipedia.org/wiki/Pipeline_\(software\)](https://en.wikipedia.org/wiki/Pipeline_(software))

FACE RECOGNITION SYSTEM OF THE SERVICE ROBOT

Lungin Andrey Konstantinovich

Children's technology Park Kvantorium Photonics Perm,
iam.prostoi.chelovek@gmail.com

Face is the most important tool of the nonverbal communication. Face can provide a huge amount of information: gender, age, nationality. Unique facial features allow to precisely identify a human; and facial expressions and eye direction allow to understand an emotion and a subject of speech. It is especially useful for leading a conversation [1]. That's why the face recognition system is one of the service robot's main systems (the same is true for any other robot, which does interact with humans).

The goal of the project is to create a modular face recognition²⁰ system, which can work in a real time, with a high accuracy and a maximum stability.

Keywords: face recognition, face localization, face identification, face normalization, OpenCV, dlib, C++

²⁰ The term "face recognition" in this context refers to a broader area than "face identification" – extracting all of the possible data from the image of humans' face

АППАРАТ ДЛЯ ПЕРЕРАБОТКИ ПЛАСТИКОВЫХ ОТХОДОВ В ФИЛАМЕНТ ДЛЯ 3D ПЕЧАТИ

*Богданов Даниил Викторович, Наумов Иван Александрович,
Михеев Данил Андреевич, руководитель* *Леонова Вера Сергеевна*
Детский технопарк «Кванториум «Фотоника», 614002 г. Пермь,
25 октября, д. 64, leonovav@kvantorium-perm.ru

Какая одна из самых актуальных проблем экологии на сегодняшний день? И конечно многие, наверняка, скажут, что это проблема пластиковых отходов. И сразу напрашивается вопрос: «А как решить данную проблему и при этом как-то что-то на этом заработать?» Есть множество способов, например: перерабатывать использованный пластик в новый, делать пластик не из всяких веществ, а из органики, и так далее. Всех способов не перечислишь. Но много ли выгоды вы с этих идей получите? Да, возможно. Но не кажется ли вам, что это нужно трансформировать в то, что на данный момент набирает большие обороты практически во всех отраслях человеческой деятельности. А именно 3D-печать. Вот почему решили превращать уже использованный пластик в то, что сейчас и в будущем имеет ценность.

Ключевые слова: переработка пластика, 3D печать, аддитивные технологии.

Переработка пластиковых отходов поможет в сохранении экологии на земле – тонны ненужного мусора станут полезными. Совместно, с помощью экологии будет идти и коммерческий успех переработки. Количество пластиковых бутылок не поддается исчислению, и многие компании продают тонны этой “ценности” очень дешево, один килограмм потенциального филамента для 3D печати стоит в 100 раз меньше, чем уже готовый филамент. Интерес со стороны людей в такой выгодной переработке, даст толчок к тому, что люди перестанут просто так раскидываться пластиком, они захотят его копить и сдавать. Пластик станет не просто мусором, который нужно выкидывать, а настоящим источником прибыли. Источником, который будет приносить большую пользу для сохранения нашей планеты. Вы можете себе представить? – пластик, что недавно отравлял водоемы и почву, стал новой ступенью по внедрению аддитивных технологий в обычную жизнь.

На просторах интернета можно найти большой поток видео материалов и статей на тему переработки пластика. В основном это «колхозные» агрегаты, установленные гараже на которых перемалывают и расплавляют пластик для последующей отливки в формы. А переработкой пластика в филамент для 3D печати занимаются лишь единицы, и то информацию о них можно найти лишь на зарубежных сайтах. Из аппаратов для домашнего

использования можно лишь выделить устройства корейского производства, но его стоимость достаточно велика и переплавляет пластик – лишь в жидкую массу для отливки.

В отличие от аналогов, нашей идеей стало создание модульного аппарата для домашнего использования, подходит для любителей домашней 3д печати. Переплавляет пластиковые отходы (отходы 3D печати, пластиковые бутылки и т.д.) в нить для дальнейшего использования в 3 д принтере. При этом, данный комплекс должен иметь низкую стоимость (относительно существующих решений) и малые габариты. Это позволит сделать переработку доступной для большого круга энтузиастов и предпринимателей.

Первый модуль измельчает пластик, второй-разогревает и вытягивает через экструдер в нить нужного сечения. можно использовать как оба модуля совместно, так и каждый в отдельности.

Для воплощения этой идеи нами предлагается создание аппарата по переработке пластика (рис. 1). Этот аппарат способен перерабатывать пластиковые бутылки в пластиковую нить толщиной 1,75 – 2,85 мм, что будет достаточно удобно для дальнейшего применения в аддитивных технологиях.



Рисунок 1. Внешний вид прибор

Наш аппарат (рис.2) состоит из загрузочного бункера, представляющего собой воронку, шредера, состоящего из попарно соединенных циркулярных металлических двенадцати ножей, диаметром 130 мм, которые приводятся в движение двумя электродвигателями мощность 300 ватт, экструдера, предназначенного для расплавления пластика и содержащего нагревательный элемент который может разогреть поступающий пластик до температура 250 -280 ° С и шнека, диаметром 14 мм и длиной 35 мм, предназначенного для продавливания расплавленного пластика, приводящего в движение шаговым электродвигателем, камеры

охлаждения, представляющей собой резервуар с циркулирующей водой комнатной температуры и намоточного механизма, состоящего из роликовой системы, которая протягивает нить, и вала, приводящего в движение электродвигателем мощностью 100 ватт, к которому и крепится катушка.

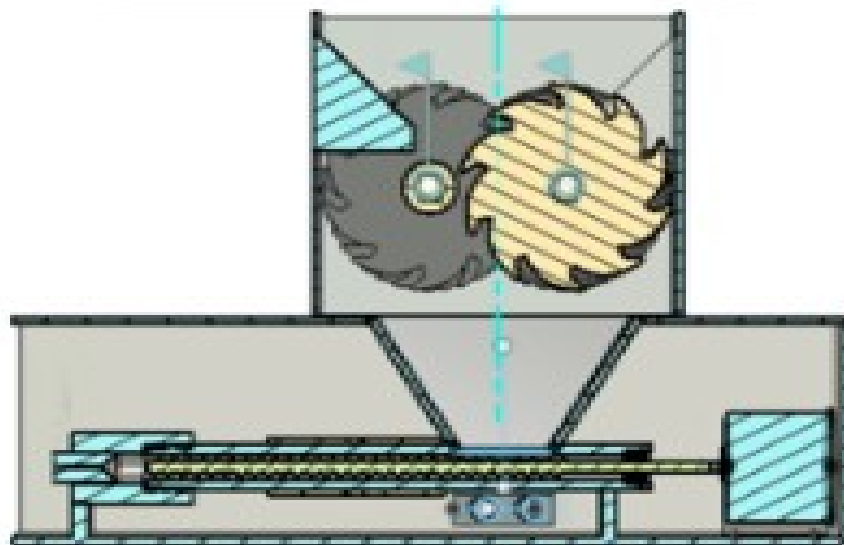


Рисунок 2. Аппарат в разрезе

Принцип работы нашего аппарата: пластик загружается в бункер, из которого, под воздействием силы тяжести, он попадает в шредер. В шредере пластик мелко дробится на очень мелкие кусочки и попадает в экструдер, где он расплавляется, далее эта расплавленная масса проталкивается шнеком в отверстие нужной толщины в 1,75 или 2,85 мм, попадает в охлаждающую камеру, где она охлаждается в воде комнатной температуры, благодаря чему получается пластиковая нить, которая затем по роликовой системе и вращению вала наматывается на катушку.

Типы пластика, которые сможет перерабатывать «Аппарат для переработки пластиковых отходов в филамент для 3D печати»:

- PET или PETE – самый распространенный вид пластика, используемый для упаковки напитков. Легко перемалывается и расплавляется;
- PE-HD или HDPE – применяется для упаковки молочных продуктов, воды, сока. Легко перемалывается и расплавляется, имеет большой потенциал для 3D-печати;
- PE-LD или LDPE – мягкий вид пластика, поддающийся переработке;
- PP – вид пластика, который применяют для крупных объектов, например, пластиковой мебели;
- Другие виды пластика: DVD, CD, солнцезащитные очки и др.

В итоге можно сказать, что наш проект подходит под современные тенденции развития и еще долго будет актуален, также несет огромный плюс экологии и способен приносить доход, что тоже очень важно.

Библиографический список

1. Быстров Г.А., Гальперин В.М., Титов Б.П. Обезвреживание и утилизация отходов в производстве пластмасс. Л.: Химия, 1982. С. 178 – 214.
2. В.В. Кафаров. Принципы создания безотходных технологий химических производств, М.: Химия, 1982. С. 285.
3. Цыганков А.П., Балацкий О.Ф., Сенин В.М. Технический прогресс – химия – окружающая среда. М., Химия, 1979. 296 с.
4. Д.А. Арашкевич. Вторичная переработка отходов пластмасс и специальные роторные дробилки / Пластические массы, 2003, № 5, с. 13
5. А.П. Цыганков, В.Н. Сенин. Циклические процессы в химической технологии. Основы безотходных производств. М.: Химия, 1988. С. 120 – 131.

A MACHINE FOR RECYCLING PLASTIC WASTES INTO A 3D PRINTING FILAMENT

*Bogdanov Daniil Vik., Naumov Ivan Al., Mikheyev Danil And., rukovoditel'
Leonova Vera Ser.*

Detskiy tekhnopark «Kvantorium «Fotonika», 614002 g Perm', 25 oktyabrya, d. 64,
leonovav@kvantorium-perm.ru

What is one of the most pressing environmental problems today? And of course, many will probably say that this is a problem of plastic waste. And the question immediately arises: "How to solve this problem and at the same time somehow earn something on it?" There are many ways, for example: recycle used plastic into new one, make plastic not from any substances, but from organic matter, and so on.
Key words: plastic processing, 3D printing, additive technologies.

УДК 519.2

О МОЩНОСТИ КРИТЕРИЯ НОРМАЛЬНОСТИ, ОСНОВАННОМ НА РАЗБИЕНИИ НОСИТЕЛЯ РАСПРЕДЕЛЕНИЯ НА 2 ЧАСТИ, НА СИММЕТРИЧНЫХ АЛЬТЕРНАТИВАХ

Балюкина Людмила Анатольевна, Чичагов Владимир Витальевич
Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, chichagov@psu.ru

Предложен критерий нормальности элементов независимой повторной выборки, являющийся аналогом статистического критерия, предназначенного для проверки гипотезы о значении вероятности. Альтернативной гипотезой является предположение о некотором

симметричном сдвиго-масштабном распределении, статистикой критерия – функция от вероятности и частоты попадания элементов выборки в интервал симметричный относительно среднего выборки. Найдено асимптотическое распределение частоты в условиях справедливости нулевой и конкурирующей гипотез. Асимптотическое разложение функции мощности критерия может быть использовано для нахождения значения вероятности, обеспечивающего его наибольшую мощность.

Ключевые слова: статистический критерий, мощность, асимптотическое распределение.

Имеется выборка из независимых случайных величин, имеющих одно и то же симметричное распределение плотностью распределения вероятностей $f(x|\theta_1, \theta_2)$. Рассмотрим задачу проверки гипотезы

$$H_0 : f(x|\theta_1, \theta_2) = \frac{1}{\theta_2 \sqrt{2\pi}} \exp\left\{-\frac{(x-\theta_1)^2}{2\theta_2^2}\right\}, x \in \mathbb{R} \quad (1)$$

против гипотезы

$$H_1 : g(x|\theta_1, \theta_2) = \frac{1}{c\theta_2} g_0\left(\frac{x-\theta_1}{c\theta_2}\right), x \in \mathbb{R} \quad c > 0, \quad (2)$$

с параметром сдвига $\theta_1 \in \mathbb{R}$ и параметром масштаба $c\theta_2 > 0$, где $g_0(t), t \in \mathbb{R}$ – известная плотность распределения случайной величины η_0 такая, что

$$E\eta_0 = \int_{-\infty}^{\infty} t g_0(t) dt = 0, \quad V\eta_0 = \int_{-\infty}^{\infty} t^2 g_0(t) dt = 1.$$

Для решения этой задачи предлагается критерий U_n , основывающийся на статистике $U_n = (N_\Delta - np_0) / \sqrt{n[p_0(1-p_0) - 2z_0^2\phi^2(z_0)]}$, где N_Δ – число элементов выборки X_1, \dots, X_n принадлежащих интервалу $\Delta = (\bar{X} - z_0 S, \bar{X} + z_0 S)$, z_0 – квантиль уровня $(1+p_0)/2$ стандартного нормального распределения, $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, S = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$, p_0 – заданное значение вероятности попадания элементов выборки в интервал $(\theta_1 - z_0\theta_2, \theta_1 + z_0\theta_2)$, $\phi(x) = \frac{1}{\sqrt{2\pi}} \exp\{-x^2/2\}$ – плотность стандартного нормального распределения.

Критерий U_n . Нулевую гипотезу будем принимать с асимптотическим уровнем значимости α , если выполняется неравенство $|U_n| < z_\alpha$, где z_α – квантиль уровня $1-\alpha/2$ стандартного нормального распределения

Замечание 1. Критерий U_n является аналогом критерия Рао-Робсона-Никулина [1, 2], соответствующего разбиению числовой оси на 2 части. С другими критериями нормальности можно познакомиться в работах Б.Ю. Лемешко (см., например, [3, 4]). Проведенное в [3] исследование позволило установить оптимальное в смысле максимума информации разбиение

числовой оси для построения критериев хи-квадрат Пирсона и Рао–Робсона–Никулина с наибольшей мощностью в зависимости от количества интервалов разбиения. Однако, выбор критерия оптимальности разбиения был сделан исходя из анализа группированных данных. В то же время в [5] высказано мнение о том, что для достижения высокой мощности критерием типа хи-квадрат не требуется большого числа интервалов разбиения. При этом ничего не было сказано о том, каким образом осуществить разбиение числовой оси на интервалы. В связи с этим в данной работе рассмотрен вариант критерия Рао–Робсона–Никулина, основывающийся на нестандартном разбиении числовой оси на две непересекающиеся области. Одна из частей разбиения – некоторый интервал числовой оси с центром, совпадающим с генеральным средним наблюдаемой случайной величины. Другая часть разбиения – остальная часть числовой оси.

Теорема 1. Пусть X_1, \dots, X_n – выборка, элементы которой являются независимыми случайными величинами, имеющими симметричное распределение с плотностью распределения вероятностей (3), которая непрерывна относительно (x, θ) и непрерывно дифференцируема по θ . Информационная матрица распределения (3) положительно определена при всех возможных значениях параметров. Тогда при $n \rightarrow \infty$ статистика $Y_n^* = \frac{N_\Delta - np_1}{\sqrt{n}}$, где $p_1 = \int_{-z_0}^{z_0} g_0(t) dt$ – заданное число, а N_Δ – число элементов выборки X_1, \dots, X_n принадлежащих интервалу $\Delta = (\bar{X} - z_0 S, \bar{X} + z_0 S)$, допускает следующее асимптотическое представление:

$$Y_n^* = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left[I \left(-z_0 < \frac{X_i - \theta_1}{c\theta_2} < z_0 \right) - p_1 \right] + 2\sqrt{n} z_0 g_0(z_0) \left(\frac{S/c - \theta_2}{\theta_2} \right) + o_p(1). \quad (3)$$

Доказательство. Заметим, что в случае распределения (3): $EX_1 = \theta_1, \mathbf{V}X_1 = (c\theta_2)^2$. Поэтому при $n \rightarrow \infty$ имеет место сходимость по вероятности

$$\bar{X} \rightarrow \theta_1, \quad S \rightarrow c\theta_2, \quad (4)$$

а интервалу $\Delta = (\bar{X} - z_0 S, \bar{X} + z_0 S)$ соответствуют следующие точечные оценки параметров распределения (3): $\tilde{t}_1, \dots, \tilde{t}_2, \dots$

Воспользуемся следующим результатом из [6]:

$$Y_n^* = \frac{N_\Delta - np_1}{\sqrt{n}} = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left[I \left(-z_0 < \frac{X_i - \theta_1}{c\theta_2} < z_0 \right) - p_1 \right] - \sqrt{n} \int_{\Delta} \frac{\partial}{\partial \theta^T} g(y|\theta) dy (\tilde{t}_1, \dots, \tilde{t}_r). \quad (5)$$

Положим $y_L = \theta_1 - z_0 c\theta_2, y_U = \theta_1 + z_0 c\theta_2$. Дифференцируя тождество

$$\int_{y_L}^{y_U} g(x|\theta) dx = \int_{-z_0}^{z_0} g_0(t) dt = p_1, \quad \forall \theta \in \Theta = \square \quad \square$$

по θ , получим равенство

$$\begin{aligned} \int_{y_L}^{y_U} \frac{\partial}{\partial \theta^\top} g(x|\theta) dx &= - \left[g(y_U|\theta) \frac{\partial y_U}{\partial \theta^\top} - g(y_L|\theta) \frac{\partial y_L}{\partial \theta^\top} \right] = \\ &= - \frac{1}{c\theta_2} [g_0(z_0)(1, cz_0) - g_0(-z_0)(1, -cz_0)] = - \frac{1}{\theta_2} 2z_0 g_0(z_0)(0,1). \end{aligned}$$

Подставляя полученное выражение в (5), завершим доказательство теоремы.

Следствие 1. Пусть выполнены условия теоремы 1. Если справедлива нулевая гипотеза H_0 , то при $n \rightarrow \infty$

$$Y_n^* = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left\{ \left[I \left(-z_0 < \frac{X_i - \theta_1}{\theta_2} < z_0 \right) - p_0 \right] + z_0 \phi(z_0) \left[\left(\frac{X_i - \theta_1}{\theta_2} \right)^2 - 1 \right] \right\} + o_p(1). \quad (7)$$

Если справедлива конкурирующая гипотеза H_1 , то при $n \rightarrow \infty$

$$Y_n^* = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left\{ \left[I \left(-z_0 < \frac{X_i - \theta_1}{c\theta_2} < z_0 \right) - p_1 \right] + z_0 g_0(z_0) \left[\left(\frac{X_i - \theta_1}{c\theta_2} \right)^2 - 1 \right] \right\} + o_p(1). \quad (8)$$

Доказательство. В условиях справедливости конкурирующей гипотезы H_1

$$\begin{aligned} 2z_0 \sqrt{n} g_0(z_0) \frac{S/c - \theta_2}{\theta_2} &= 2z_0 \sqrt{n} g_0(z_0) \frac{S - c\theta_2}{c\theta_2} = \\ &= \frac{\sqrt{n} z_0 g_0(z_0)}{(c\theta_2)^2} \left[(\overline{X^2} - \mathbf{E}X_1^2) - 2\theta_1(\bar{X} - \theta_1) \right] + o_p(1) = \sqrt{n} z_0 g_0(z_0) \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{X_i - \theta_1}{c\theta_2} \right)^2 - 1 \right] + o_p(1), \end{aligned}$$

откуда следует справедливость (8). Нулевой гипотезе соответствуют $c=1, g_0(z) = \phi(z)$. Поэтому верно (7).

Следствие 2. Пусть выполнены условия теоремы 1. Если справедлива нулевая гипотеза H_0 , то последовательность случайных величин $\{Y_n^*\}$ при $n \rightarrow \infty$ асимптотически нормальна с нулевым средним и асимптотической дисперсией $B_0^2 = p_0(1-p_0) - 2z_0^2 \phi^2(z_0)$. Если справедлива конкурирующая гипотеза H_1 , то последовательность случайных величин $\{Y_n^*\}$ при $n \rightarrow \infty$ асимптотически нормальна с нулевым средним и асимптотической дисперсией

$$B_1^2 = p_1(1-p_1) + [z_0 g_0(z_0)]^2 (\nu_4 - 1) + 2z_0 g_0(z_0) \int_{-z_0}^{z_0} (t^2 - 1) g_0(t) dt, \quad \text{где}$$

$$\nu_4 = \int_{-\infty}^{\infty} t^4 g_0(t) dt.$$

Доказательство. В силу центральной предельной теоремы при условии справедливости конкурирующей гипотезы H_1 последовательность случайных величин

$$Y_n^* = \frac{1}{\sqrt{n}} \sum_{i=1}^n \left\{ \left[I \left(-z_0 < \frac{X_i - \theta_1}{c\theta_2} < z_0 \right) - p_1 \right] + z_0 g_0(z_0) \left[\left(\frac{X_i - \theta_1}{c\theta_2} \right)^2 - 1 \right] \right\} + o_p(1)$$

при $n \rightarrow \infty$ асимптотически нормальна со средним, равным

$$\mathbf{E} \left\{ \left[I \left(-z_0 < \frac{X_i - \theta_1}{c\theta_2} < z_0 \right) - p_1 \right] + z_0 g_0(z_0) \left[\left(\frac{X_i - \theta_1}{c\theta_2} \right)^2 - 1 \right] \right\} = 0 \quad (9)$$

и дисперсией, равной

$$\begin{aligned} B_1^2 &= \mathbf{V} \left\{ \left[I \left(-z_0 < \frac{X_i - \theta_1}{c\theta_2} < z_0 \right) - p_1 \right] + z_0 g_0(z_0) \left[\left(\frac{X_i - \theta_1}{c\theta_2} \right)^2 - 1 \right] \right\} = \\ &= p_1(1-p_1) + 2[z_0 g_0(z_0)]^2 \int_0^\infty [t^2 - 1]^2 g_0(t) dt + 2z_0 g_0(z_0) \int_{-z_0}^{z_0} (t^2 - 1) g_0(t) dt = \\ &= p(1-p) + [z_0 g_0(z_0)]^2 (\nu_4 - 1) + 2z_0 g_0(z_0) \int_{-z_0}^{z_0} (t^2 - 1) g_0(t) dt. \end{aligned}$$

Подставляя в последнее выражение $c = 1, g_0(z) = \phi(z), \nu_4 = 3$, вычислим

$$\begin{aligned} B_0^2 &= p_0(1-p_0) + 2z_0^2 \phi^2(z_0) + 2z_0 \phi(z_0) \int_{-z_0}^{z_0} (t^2 - 1) \phi(t) dt = \\ &= p_0(1-p_0) + 2z_0^2 \phi^2(z_0) + 2z_0 \phi(z_0) [-2z_0 \phi(z_0)] = p(1-p) - 2z_0^2 \phi^2(z_0). \end{aligned}$$

Наконец, подобно (9), при условии справедливости нулевой гипотезы H_0 устанавливается асимптотическая нормальность последовательности случайных величин $\{Y_n^*\}$ со средним, равным нулю.

Замечание 2. Из следствия 2 вытекает, что статистика критерия U_n при условии справедливости нулевой гипотезы H_0 асимптотически нормальна с параметрами 0 и 1. Это означает, что неравенство $|U_n| < z_{(1+\alpha)/2}$ определяет область принятия нулевой гипотезы с асимптотическим уровнем значимости критерия α .

Основываясь на теореме 1 и следствиях к ней, получим оценку мощности предложенного критерия по отношению к альтернативной гипотезе H_1 .

Теорема 2. Пусть X_1, \dots — выборка, элементы которой являются независимыми случайными величинами, имеющими симметричное распределение с плотностью распределения вероятностей вида

$$g(x | \theta_1, \theta_2) = \frac{1}{c\theta_2} g_0 \left(\frac{x - \theta_1}{c\theta_2} \right), c > 0, \theta_2 > 0. \quad (10)$$

Если выполнены условия теоремы 1, а p_0 — заданная вероятность попадания элементов выборки в интервал $(\theta_1 - z_0\theta_2, \theta_1 + z_0\theta_2)$ в условиях справедливости нулевой гипотезы H_0 , где z_0 — квантиль уровня $(1+p_0)/2$ стандартного нормального распределения, $p_1 = \int_{-z_0}^{z_0} g_0(t) dt$, $\nu_4 = \int_{-\infty}^{\infty} t^4 g_0(t) dt$, то при $n \rightarrow \infty$

$$\mathbf{P}(|U_n| \geq u_\alpha) = 1 - \Phi\left(-\frac{\sqrt{n}(p_1 - p_0)}{B_1} + u_\alpha \frac{B_0}{B_1}\right) + \Phi\left(-\frac{\sqrt{n}(p_1 - p_0)}{B_1} - u_\alpha \frac{B_0}{B_1}\right) + o_p(1),$$

где

$$B_0 = \sqrt{p_0(1-p_0) - 2z_0^2\phi^2(z_0)},$$

$$B_1 = \sqrt{p_1(1-p_1) + [z_0 g_0(z_0)]^2 (v_4 - 1) + 2z_0 g_0(z_0) \int_{-z_0}^{z_0} (t^2 - 1) g_0(t) dt}.$$

Доказательство. В условиях справедливости конкурирующей гипотезы H_1 верно

$$\begin{aligned} \mathbf{P}(|U_n| \geq u_\alpha) &= \mathbf{P}\left(\left|\frac{N_\Delta - np_0}{B_0 \sqrt{n}}\right| \geq u_\alpha\right) = \mathbf{P}\left(\left|\frac{N_\Delta - np_1 + n(p_1 - np_0)}{B_1 \sqrt{n}} \frac{B_1}{B_0}\right| \geq u_\alpha\right) = \\ &= \mathbf{P}\left(\left|\frac{N_\Delta - np_1 + n(p_1 - np_0)}{B_1 \sqrt{n}}\right| \geq u_\alpha \frac{B_0}{B_1}\right) = \\ &= 1 - \mathbf{P}\left(-\frac{\sqrt{n}(p_1 - p_0)}{B_1} - u_\alpha \frac{B_0}{B_1} < \frac{N_\Delta - np_1}{\sqrt{n} B_1} < -\frac{\sqrt{n}(p_1 - p_0)}{B_1} + u_\alpha \frac{B_0}{B_1}\right), \end{aligned}$$

откуда и следует справедливость теоремы 2.

Библиографический список

1. Никулин М.С. Критерий хи-квадрат для непрерывных распределений с параметрами сдвига и масштаба // Теория вероятн. и ее примен. 1973. Т.18. Вып. 3. С. 583–591.
2. Bagdonavicius V., Kruopis J., Nikulin M. Nonparametric tests for complete data. London: ISTE Ltd., 2011.
3. Лемешко Б.Ю. Критерии согласия типа хи-квадрат при проверке нормальности // Измерительная техника. 2015. №6. С. 1–9.
4. Лемешко Б.Ю. Критерии проверки отклонения распределения от нормального закона. Руководство по применению. М.: ИНФРА-М, 2015.
5. Боровков А.А. Математическая статистика. // СПб.: Издательство «Лань», 2010 – С. 228–229.
6. Moore D.S. A chi-square statistic with random cell boundaries// AMS. Vol. 42. No. 1. 1971. P. 147-156.

ABOUT POWER NORMALITY TEST BASED ON PARTITION OF THE DISTRIBUTION SUPPORT INTO 2 PARTS ON SYMMETRIC ALTERNATIVES

Balyukina Ludmila A., Chichagov Vladimir V.

Perm State University, 15, Bukireva st., Perm, 614990, Russia, chichagov@psu.ru

A criterion for the normality of elements of independent resampling is proposed. It is an analogue of a statistical test that is used to test a hypothesis about a probability value. The assumption of some symmetric shift-scale distribution is an alternative hypothesis, the test statistics is a function of the probability and frequency of the sample elements falling into the interval symmetric with respect to the sample mean. Under the conditions of validity of the null and alternative hypotheses, the asymptotic frequency distribution is found. The asymptotic expansion of the test power function can be used to find the value of the probability that provides its highest power.

Keywords: statistical test, power, asymptotic distribution.

УДК 62-529

ИССЛЕДОВАНИЕ СПОСОБОВ МОНИТОРИНГА ПРОЦЕССА 3D ПЕЧАТИ

*Борисова Елизавета Романовна, Курушина Дарья Данишиловна,
Поносова Виктория Олеговна*

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
liz.borisova@mail.ru, dasha.kurushina@gmail.com, ponosovavo@gmail.com

Из-за растущей потребности в этой технологии существует потребность в защите и отслеживании 3D-печати. Чтобы контролировать стабильность и надежность процесса 3D-печати, необходимо использовать организацию системы для мониторинга работы 3D-принтера. Это не только получит гарантированный высокий балл в ожидаемое время, но и защитит оборудование от сбоев и преждевременного отказа его важных узлов. Система мониторинга позволит контролировать процесс 3D-печати в режиме реального времени и в случае прямой необходимости удаленного отключения питания принтера 3D до тех пор, пока проблема не будет решена. Система мониторинга позволит контролировать процесс 3D-печати в режиме реального времени и в случае прямой необходимости удаленного отключения питания принтера 3D до тех пор, пока проблема не будет решена.
Ключевые слова: 3D-печать, принтер, мониторинг, аддитивные технологии, программа.

В настоящее время во всем мире нарастает интерес к аддитивным технологиям. Например, в статье «Липницкий Л.А., Пильгун Т.В. – Аддитивные технологии и их перспективы в образовательном процессе» [1] указана необходимость развития у учащихся инновационного мышления. Указано, что аддитивные технологии позволяют значительно ускорить работы по проектированию и дизайну, позволяют учащимся реально оценить результаты своей работы, увеличить интерес к обучению, изменить способы представления своей работы к защите. Необходимость аддитивных технологий проявляется и в медицине: «Родригез-Сальвадор Марисела, Гарсиа-Гарсиа Леонардо Азаэль – Аддитивные производственные технологии в здравоохранении» [2]. В данной статье подчеркивается, что аддитивные производственные технологии, в частности 3D печать, – сравнительно молодое, но динамичное технологическое направление, меняющее облик многих секторов. В связи с ростом потребности в данной технологии появляется и потребность в защите и мониторинге 3D печати.

Для контроля стабильности и надежности процесса 3D-печати необходимо использовать организацию системы мониторинга работы 3D-принтера. Это не только получит гарантированный высокий балл в ожидаемое время, но и защитит оборудование от сбоев и преждевременного отказа его важных узлов.

Чтобы понять важность этого вопроса, мы перечислили наиболее важные из возможных проблем, которые могут возникнуть при работе с настольным принтером 3D[3]:

1. Низкая адгезия (или вообще ее отсутствие) нижних образовавшихся слоев 3D-объекта с печатной платформой. В результате можно переместить часть или полностью отделить изделие от платформы и хаотично передвигать ее по ней после ее удержания экструдером. Это может привести к тому, что полимерная нить нагревается, не нанося на предварительно рассчитанную программу заговора 3D-объекта, начинает образовываться застывшая в пространстве "сгустки", постепенно приклеиваясь к насадке экструдера. В том случае, если такой эффект на насадку будет длительным, возможны повреждения. Например, расплавленный пластик может полностью заполнить пространство вокруг сопла, а затем непосредственно в кронштейн экструдера и затвердеть. Это может также привести к неисправности механики, ответственной за движение HU тележки, и не удастся дорогостоящий экструдер при очистке экструдера из закаленного пластика возможно разделение термоденсора или шнура питания, что приводит к нагревательному элементу экструдера.

2. Нестандартная катушка полимерной нити на бобине, что приводит к образованию узлов, которые препятствуют ее подаче в узел экструдера. Или застревание нити в самом узле экструдера из-за брака материала, разрешенного в его производстве, и существенного отклонения от номинального диаметра 1 мм. В этом случае, если своевременно не обнаружена такая проблема, длительная работа принтера 3D находится в режиме ожидания. 3D-объект в любом случае будет сломан, а часть

материала (часто значительная), ресурс системы 3D-принтера, электричество теряется.

3. Различные непредвиденные обстоятельства при работе 3D-принтера или завершении цикла 3D-печати и после этого долго просто включаются 3D-принтеры. Особое значение они приобретают, если необходимо создать, получить в материале большой 3D-объект, время изготовления которого может длиться до нескольких дней.

Ниже представлена принципиальная схема построения предлагаемой нами системы мониторинга работы настольного 3D принтера (см. Рис.1).

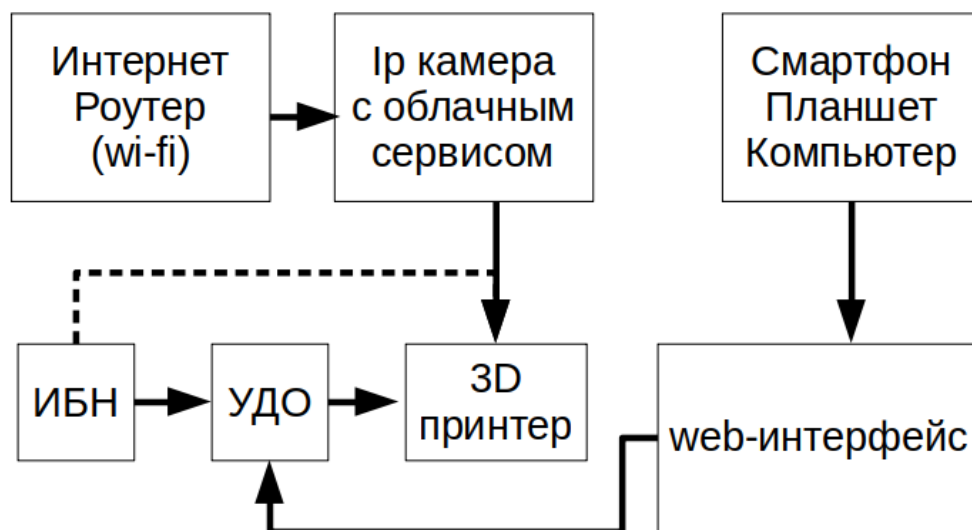


Рисунок 1. Мониторинг процесса 3D печати

ИБП – источник бесперебойного питания.

УДО – устройство дистанционного отключения электропитания.

Существуют различные способы мониторинга процесса печати. Рассмотрим одну из них.

Система мониторинга позволит контролировать процесс 3D-печати в режиме реального времени, а в случае прямой необходимости удаленно отключать питание принтера 3D до тех пор, пока не будет решена проблема. С помощью IP-камеры с облачным сервисом можно наблюдать за процессом работы 3D-принтера из любого места, где есть подключение к интернету, а в случае обнаружения неисправностей-в любое время удаленно отключать питание 3D-принтера с планшета, смартфона или компьютера [4].

Разработка системы мониторинга 3D принтера может оказаться полезным нововведением для предприятия, занимающихся серийным производством, ведь вся информация о находящемся в процессе печати объекте будет выводиться на дисплей. Поэтому специалист, контролирующий процесс печати, всегда будет иметь возможность увидеть то, каким будет готовое изделие, а в случае непредвиденных ситуаций получит возможность внести какие-либо изменения в процесс.

Библиографический список

1. Липницкий Л.А., Пильгун Т.В. Аддитивные технологии и их перспективы в образовательном процессе // Системный анализ и прикладная информатика. 2018. №3. URL: <https://cyberleninka.ru/article/n/additivnyye-tehnologii-i-ih-perspektivy-v-obrazovatelnom-protsesse> (дата обращения: 10.09.2020).
2. Родригез-Сальвадор Марисела, Гарсиа-Гарсиа Леонардо Азаэль Аддитивные производственные технологии в здравоохранении // Форсайт. 2018. URL: <https://cyberleninka.ru/article/n/additivnyye-proizvodstvennyye-tehnologii-v-zdravoohranenii> (дата обращения: 10.09.2020).
3. Мониторинг процесса 3D печати // 3dbot.ru URL: <http://blog.3dbot.ru/raznoe-o-3d/monitoring-processa-3d-pechati.html> (дата обращения: 10.09.2020).
4. Мониторинг процесса 3D печати // 3dtoday.ru URL: <https://3dtoday.ru/blogs/3dfirst/monitoring-of-the-process-of-3d-printing/?commentId=968> (дата обращения: 10.09.2020).

RESEARCH ON WAYS TO MONITOR THE 3D PRINTING PROCESS

Borisova, Elizaveta R., Kurushina Daria D., Ponosova Victoria O.

Perm State National Research Politechnical University, 614000, Russia, Perm, Komsomolsky Av. 29, liz.borisova@mail.ru, dasha.kurushina@gmail.com, ponosovavo@gmail.com

Due to the growing need for this technology, there is a need to protect and track 3D printing. To control the stability and reliability of the 3D printing process, you need to use the organization of the system to monitor the operation of the 3D printer. This will not only get a guaranteed high score in the expected time, but also protect the equipment from failures and premature failure of its important nodes. The monitoring system will allow you to monitor the 3D printing process in real time and in the event of a direct need to remotely turn off the power of the 3D printer until the problem is resolved. The monitoring system will allow you to monitor the 3D printing process in real time and in the event of a direct need to remotely turn off the power of the 3D printer until the problem is resolved.

Key words: 3D printing, printer, monitoring, additive technologies, program.

ПОСТРОЕНИЕ МОДЕЛИ ДВИЖЕНИЯ КИСТИ РУКИ НА БАЗЕ МИКРОЭЛЕКТРОМЕХАНИЧЕСКИХ СЕНСОРОВ И АЛГОРИТМА ДИНАМИЧЕСКОЙ ТРАНСФОРМАЦИИ ВРЕМЕННОЙ ШКАЛЫ

Гайнияров Игорь Мадыхатович

Институт математики и механики им. Н.Н.Красовского УрО, 620108, Россия,
г. Екатеринбург, ул. Софьи Ковалевской, д. 16, i.m.gainiarov@imm.uran.ru

Стародубцев Илья Сергеевич

Институт математики и механики им. Н.Н. Красовского УрО, 620108, Россия,
г. Екатеринбург, ул. Софьи Ковалевской, д. 16;
Уральский федеральный университет, 620075, Россия, г. Екатеринбург,
пр. Ленина, 51, starodubtsevis@robolab.tk

Рассмотрена проблема оперативного сравнения паттернов движения с применением микроэлектромеханических сенсоров. Захват движений на длительном промежутке времени является затруднительной задачей ввиду фундаментальных ограничений, принятых для классической обработки данных с представленных сенсоров. Поэтому в данной работе представлен метод формирования модели движения в условиях, когда нам заранее известно какие типы двигательной активности будут представлены в будущем. Были выделены этапы предварительной подготовки, снижения размерности данных и непосредственно сравнения их между собой. Для эффективного решения задачи авторами предлагается подход на основе корреляционного анализа, векторах фиксированной размерности (по аналогии с word2vec), вейвлет преобразования и алгоритма динамической трансформации временной шкалы из динамического программирования. Предполагается, что разработанный метод позволит решить задачу методов моделирования различных движений с целью применения в сферах удаленного образования, телемедицинского мониторинга и захвата мелкой моторики в виртуальной реальности.

Ключевые слова: МЭМС, захват движения, алгоритм динамической трансформации временной шкалы, модель движения, word2vec.

Введение

В научных, образовательных и коммерческих организациях повышенное внимание уделяется вопросам качественного удаленного образования, телемедицинского мониторинга и эффекта погружения в VR.

Личное присутствие специалиста обычно необходимо на первоначальной диагностике, а далее требуются корректирующие встречи. Например, так происходит обучение бегу, постановки голоса или игре на

фортепиано. Так же такое решение полезно для тренеров по физической реабилитации, так как всегда есть момент, когда пациента отпускают на долечивание в домашние условия. Эти примеры объединяет тот факт, что для каждого из них существует эталонная техника, которая выражается в наборе правильных действий и положений тела (или множестве динамических и статических параметров). Эффект присутствия в VR усиливается вместе с тем, на сколько точно ощущения в виртуальной среде соответствуют реальному образу. В этом случае важно оцифровывать и мелкую моторику.

Эти действия можно оцифровать и классифицировать как физиологические показатели человека при помощи инерциальных микроэлектромеханических сенсоров ориентации в пространстве [1]. Для этого необходима разработка специального аппаратно-программного комплекса с особенными свойствами. Во-первых, нужна миниатюрность. Во-вторых, совместимость с мобильными устройствами, планшетами и ноутбуками. В-третьих, система должна быть достаточно производительной, чтобы успевать анализировать либо в режиме реального времени, либо спустя небольшой промежуток времени после завершения записи.

Существует множество способов оптимизации работы подобных систем, однако они не всегда учитывают физиологическую специфику расположения сенсоров.

1. Подготовка к моделированию движений в условиях строго заданного набора движений

В данной работе использовались сенсоры *Bosch Sensortec BMI160*. Каждая плата из себя представляет одновременно и трехосевой акселерометр и трехосевой гироскоп. Гироскоп получает значения угловой скорости, а акселерометр углового ускорения в динамике. В итоге получается, что у каждого сенсора имеется по шесть строго заданных потоков данных, которые работают независимо друг от друга. Корреляция значений начинает появляться только при наличии объединяющего движения.

Зачастую для обработки данных о движении обычно применяют следующие алгоритмы:

- Маджвика;
- Махони;
- Комплементарный первого и второго порядков;
- Тригонометрического преобразования проекций на вектор гравитации «atan2»;
- Интегральное суммирование значений по осям гироскопа.

Однако в данном случае эти алгоритмы неприменимы, так как рассматривают данные в виде углов поворота. В рассматриваемом случае ближе будет пример из сферы обработки естественного языка (ОЕС) *word2vec* [2]. Его смысл можно описать как цифровой след. Только в ОЕС определенные слова преобразуются в вектор фиксированной размерности более широкого диапазона, а в приведенном подходе вместо

слов – движения, и вектор фиксированной размерности имеет естественное верхнее ограничение в виде числа независимых потоков сенсоров.

Выбор такого подхода данных связан с отсутствием нарастающей ошибки при интегральной оценке последовательности данных.

1.1 Определение избыточных потоков данных

Во время работы по оцифровке движения для заранее заданного набора действий выполняется съём данных с применением максимально информативного набора сенсоров, повторяющих набор для полноскелетного захвата движений [3].

Однако такой набор сенсоров зачастую является избыточным. Поэтому представляется разумным шагом провести корреляционный анализ между всеми потоками данных, получая таким образом квадратную матрицу взаимных корреляций. Убирая потоки от «дублирующих» сенсоров можно снизить число применяемых потоков от 13% до 75%. Критерий отбраковки одного из двух связанных потоков связан с минимизацией числа сенсоров, которые можно убрать из системы. Таким образом, если окажется что если хотя бы у одного сенсора все его потоки линейно коррелируют с потоками других сенсоров, то в первую очередь надо убирать именно потоки данных, расположенных на этом физическом сенсоре. Так же должно остаться четное число потоков данных.

1.2 Подготовка данных для дискретного вейвлет преобразования

Важным условием для применения вейвлет преобразования для данных о движении, полученных с МЭМС является порядок потоков. Перед преобразованием они должны быть отсортированы согласно одноименным направлениям на разных сенсорах. Так после потока данных гироскопа по оси X для первого сенсора должен идти следом поток данных гироскопа по оси X для второго сенсора, далее для третьего и до конца. По такому же принципу нужно отсортировать одноименные направления других сенсоров.

Для сохранения основной картины и удаления шумов применяются коэффициенты аппроксимации в вейвлет преобразовании. Причем стоит помнить, что это дискретное преобразование и по правилу Найквиста с каждым уровнем преобразования число потоков уменьшается вдвое. Так имея на входе 96 потоков после первого уровня преобразования, их остается 48. На втором уровне 24 потока.

Уровень вейвлет преобразования необходимо выбрать исходя из того уровня, когда разноименные потоки начинают смешиваться между собой.

Таким образом данные приходят в компактный вид, достаточный для быстрой работы алгоритма динамической трансформации временной шкалы (ДТВШ) [4]. Все движения будут преобразованы в вектор фиксированной размерности, равной размерности вектора после дискретного вейвлет преобразования.

2. Применение алгоритма динамической трансформации временной шкалы

Одно из первых успешных применений алгоритма ДТВШ было в сфере распознавания речи. С ростом популярности MoCap систем на основе МЭМС

в 2000 годах алгоритм ДТВШ начал применяться и в системах распознавания жестов. Жесты представляют из себя как статичные положения суставов, так и их динамическое изменение во времени. В данной работе такие динамические изменения называются движениями.

На этом этапе мы должны иметь записанные эталонные движения, в формате полученном на прошлом шаге. Каждый паттерн представляет из себя последовательно измеренные через некоторые промежутки времени данные записи или временной ряд в смысле определения Дэвида Бриллинджера и Джорджа Бокса [5].

Визуально алгоритм сравнения двух паттернов можно показать на рисунке (Рис. 1) на фоне евклидовой метрики.




Рисунок 1. Сопоставление паттернов по (а) евклидовой метрике и (б) ДТВШ.

Во время сопоставления с применением евклидовой метрики каждый паттерн сравнивается с другим в этот же момент времени. Сопоставление производится один к одному. Это приводит к следующему:

- Существует чувствительность к сдвигу по времени.
- Существует чувствительность к временным искажениям.

Например, когда движение выполняют медленнее или быстрее эталона. Края паттернов могут не совпадать друг с другом.

В случае алгоритма ДТВШ края двух паттернов всегда совпадают. Возможно сопоставление один ко многим. Это позволяет избежать отрицательных следствий, характерных для евклидовой метрики.

В алгоритме ДТВШ вычисляются попарные расстояния в n -мерном арифметическом евклидовом пространстве между всеми элементами обоих паттернов в смысле определения А.Н. Колмогорова и С.В. Фомина [6].

Само движение можно разбить на несколько базовых участков-подчастей для дальнейшего ускорения работы алгоритма. В начале мы будем искать в последовательности первую часть паттерна, потом вторую и так далее. Это значительно экономит вычислительные ресурсы, так как алгоритм имеет сложность $O(n^2)$. Разделение каждого паттерна на участки возможно

сделать на основе сглаживания каждого потока данных и последующего поиска точек экстремума.

Таким образом можно сравнивать паттерны движения между собой.

Заключение

Описанная в работе задача заключалась в разработке аппаратно-программного комплекса, позволяющего:

- Оцифровывать движения кисти руки.
- Оценивать избыточность данных.
 - Понижать размерность данных.
 - Формировать эталоны движений.
 - Находить паттерны в потоках данных по заданному эталону.

Представленный подход позволяет на этапе формирования эталонной модели движения оценить степень избыточности данных, что в итоге можно использовать для ускорения работы алгоритма сравнения. В итоге анализа выводится, какие сенсоры не нужны для заданных действий.

Ключевыми идеями являются избавление от избыточности данных о движениях и отношения к данным как цифровому следу по аналогии с word2vec.

Библиографический список

1. Тарасов А. А., Стоянов Д. Д. СИСТЕМА И СПОСОБ ДЛЯ ЗАХВАТА ДВИЖЕНИЙ И ПОЛОЖЕНИЯ ТЕЛА ЧЕЛОВЕКА И ЧАСТЕЙ ТЕЛА ЧЕЛОВЕКА. – 2018.
2. Hu S. H., Li Y., Li B. Video2vec: Learning semantic spatio-temporal embeddings for video representation //2016 23rd International Conference on Pattern Recognition (ICPR). – IEEE, 2016. – С. 811-816.
3. Болдырева Е. А., Воронцова О. И. ТРЕХМЕРНАЯ СКЕЛЕТНАЯ МОДЕЛЬ ДЛЯ ИССЛЕДОВАНИЯ БИОМЕХАНИКИ ДВИЖЕНИЙ СПОРТСМЕНОВ. – 2015.
4. Алпатов А. В., Ашапкина М. С. Разработка метрик для распознавания физических упражнений в системах удаленной реабилитации //Вестник РГРТУ. – 2018. – №. 66. – С. 139.
5. Бриллинджер Д. Временные ряды. Обработка данных и теория. //под ред. А.Н. Колмогорова /М:Мир., 1980, С. 536
6. Колмогоров А.Н., Фомин С.В. Элементы теории функций и функционального анализа. //Litres, 2018. С. 48–49.

MODEL DEVELOPMENT OF HAND MOVEMENT BASED ON MICROELECTROMECHANICAL SENSORS AND DYNAMIC TIME WARPING ALGORITHM

Gajniyarov Igor M.

N.N. Krasovskii Institute of Mathematics and Mechanics (IMM UB RAS),
16 S.Kovalevskaya Str., Yekaterinburg, 620108 Russia,
i.m.gainiarov@imm.uran.ru

Starodubtsev Illya S.

N.N. Krasovskii Institute of Mathematics and Mechanics (IMM UB RAS),
16 S.Kovalevskaya Str., Yekaterinburg, 620108 Russia;
Ural Federal University, 51 Lenina str., Yekaterinburg, 620075 Russia,
starodubtsevis@robolab.tk

The problem of movement data comparison using microelectromechanical sensors is considered. Capturing movements over a time is a difficult task due to fundamental limitations associate with classical data processing for MEMS. Therefore, this paper presents a method for forming a movement model in conditions where we know in advance what types of movement activity will be received in the future. There are stages of preliminary preparation, reduction of data dimensionality and direct comparison between them in article. Authors propose an approach based on correlation analysis, fixed-dimension vectors (similar to word2vec), wavelet transform, and a dynamic time warping (DTW) algorithm from dynamic programming to effectively solve the problem. It is assumed that developed method solve the problem of modeling various movements for use in online education, telemedicine monitoring and capturing fine motor skills in virtual reality.

Key words: MEMS, motion capture, DTW, movement model, word2vec

ANALYSIS OF PSYCHOLOGICAL PROFILES OF TYPICAL TWITTER USERS WHO ACTIVELY DISCUSS COVID-19 TREATMENT²⁴

Diana Nurbakova

LIRIS UMR 5205 CNRS, INSA Lyon University of Lyon, Villeurbanne, France,
diana.nurbakova@insa-lyon.fr

Irina Ovchinnikova

Sechenov First Moscow State Medical University, Moscow, Russia,
ovchinnikova.ig@1msmu.ru

Liana Ermakova

HCTI – EA 4249, Université de Bretagne Occidentale, Brest, France,
liana.ermakova@univ-brest.fr

During the current COVID-19 pandemic, social media have become the main source of health-related information for lay people. The attitudes towards the handling of the sanitary crisis and the adoption of health policies by users can be influenced via social media. In particular, discussions about controversial COVID-19 treatments have attracted many Twitter users resulting in multiple information cascades. In this paper, we investigate psychological profiles of Twitter users who actively participated in such discussions. More precisely, we focus on the activity of ordinary users without verified accounts who have between 1 and 50 tweets about controversial treatments in our original dataset. Based on the analysis of 200 recent tweets of these users, we infer their personality traits and perform sentiment analysis. Our results show that participants of the general discussion of the COVID-19 treatment tend to score high on Neuroticism and its facets, Openness to Change and the need for Curiosity and they generally have low scores on Conscientiousness.

Key words: social media analysis, personality traits, sentiment analysis, COVID-19.

A. Motivation and Background

Personality profile of a social media user is manifested by the user's behaviour including updates, sharing visual and verbal content, participation in flesh mobs as well as by his / her language (lexical choice, lexical diversity, syntactic complexity, pragmatic acts, etc.). The personality profile can be extracted through social media analysis [1,2]. Understanding of information propagation on social media presupposes revealing of users' psychology traits since the dominant psychology traits affect the user's activity and spreading behaviour in social media.

²⁴ All authors contributed equally to the work
© Nurbakova D., Ermakova L., Ovchinnikova I., 2020

Correlation between linguistic features of a text or speech, generated by an individual, and his / her personality traits has been studied since Jungian experiments in the middle of the previous century. Nevertheless, the standard procedures of text analysis and standard psychological tests established grounds for obtaining reliable results in the last quarter of the XX century. However, the correlation is still unclear due to the impact of discourse and pragmatic factors on the text generation. Topic, genre, recipients and communicative intention determine the text peculiarities including lexical choice and syntax structure. In social media, the effect of discourse weakens thanks to less restricted norms of conversation and specific design of online communication. Research of the impact of users' personality traits on their behaviour in social media employs different tests and psychological description of the users including Big Five [3], Personal Values [4], Jungian typology (Mayor-Briggs : [5]). Researchers aim at discovering the relevance of the psychological typology for big data processing [6]. Boyd et al. [6] emphasized the productivity of extracting scripts from social media to predict a user behaviour in comparison with closed psychological questionnaires [6]. Therefore, we apply different approaches to the personality traits identification in order to obtain reliable psychology profiles.

Users' information spreading behaviour in social media differs according to their personality and psychological type [7], in terms of commenting on tweets, retweeting [8] or question answering [9]. Thus, retweeting positively correlates with *Conscientiousness*, *Openness*, and *Modesty* [8], while question answering is more common for extraverted, agreeable individuals seeking excitement with a low score on *Cautiousness* [9]. High scores on *Extraversion* and *Openness* are typical for persuasive individuals who participate in debates in contrast to those who score high on *Neuroticism* [10]. Shmueli-Scheuer argues that *Extraversion*, *Agreeableness*, and *Conscientiousness* of a reader are highly related to his/her persuasive arguments [1].

In our previous work [11], we investigated the influence of users' personality traits on their participation in information cascades about controversial COVID-19 treatments on Twitter. We distinguished seven user categories based on their profiles and activity on the social media platform. In this paper, we focus in detail on ordinary users, i.e. who do not have verified accounts and have between 1 and 50 tweets about controversial treatments in our dataset. The number of such users is 198. The motivation behind selecting this subset is twofold: 1) these users are mainly ordinary members of society and therefore, are more representative of the population and its attitudes; 2) they are active participants of information cascades without being suspected bots or spammers, contrarily to the users with 50-500 tweets about controversial treatments in our dataset. We refer to this use category as *typical users*.

We conduct an exploratory study that aims at describing a typical Twitter user who actively participates in the discussion of controversial COVID-19 treatment. Differently from our previous work [11], we try to answer two research questions:

1. What are the psychological characteristics of typical users debating on COVID-19 treatment?

2. Are these users majorly negative or positive in their argumentation?

To answer the first research questions, we analysed 200 recent tweets (end of August 2020) of each typical user in terms of Big Five personality traits and their lower level facets, Person's Needs and Personal Values with IBM Personality Insights service²⁵. Following [15,16], we also applied sentiment analysis by means of TextBlob library²⁶ in order to determine the recent psychological state of these individuals.

B. Materials and Method

We use the dataset containing 141,866 original tweets in English about controversial COVID-19 treatments (*hydroxychloroquine, remdesivir, tocilizumab, favipiravir*, etc. [17]) described in [11]. The data was collected in real time using Twitter API²⁷ via Logstash²⁸ during the period 30/03/2020-13/07/2020. Figure 1 provides the time plot of our tweet collection.

Most of the users have only one tweet in our dataset (see Fig. 2), while verified users published around 1-10 tweets about controversial treatments, in general less than 50 tweets. The authenticity of accounts is verified by Twitter if they are of public interest, e.g. accounts maintained by public figures (music, acting, government, politics, religion, media, etc.). Considering the number of tweets published by public figures as a normal tweeting rate (not bots), we decided to analyse users who tweeted with the same frequency as public figures, i.e. we selected users with less than 50 tweets about the controversial treatments in our dataset. We randomly selected 200 users from this group with respect to the limits of the number of free queries in IBM Personality Insights²⁹ service that we used to predict user personality traits. For each user, the Tweepy³⁰ module was used to retrieve the last 200 tweets at the end of August 2020. To extract the personality traits of the users under consideration, the concatenated texts of tweets for each user were passed to IBM Personality Insights service. We selected those who had at least 10 user-generated tweets (i.e. retweets were excluded), in order to ensure the minimum text length for the analysis. Thus, 180 users out of 198 generated original content of 15,995 tweets. Such user generated content then constituted the user profile for this study.

²⁵ <https://cloud.ibm.com/apidocs/personality-insights>

²⁶ <https://textblob.readthedocs.io/>

²⁷ <https://developer.twitter.com/en/docs/twitter-api>

²⁸ <https://www.elastic.co/fr/logstash>

²⁹ <https://cloud.ibm.com/apidocs/personality-insights>

³⁰ <http://docs.tweepy.org/en/latest/api.html>





Fig. 1. Tweet collection time plot Fig.



2. Number of tweets about COVID-19 treatment per user in our dataset

We used IBM Personality Insights service to predict users' personality traits, similar to the works of [8,10]. It infers psychological characteristics of an individual by analysing the user generated text. The inference is performed with respect to three personality models:

- **Big Five** personality traits (openness, conscientiousness, extraversion, agreeableness, neuroticism) together with their lower level facets detailing the corresponding trait: general dimensions characterising an individual's engagement with the world [12].
- **Person's Needs** (excitement, harmony, curiosity, ideal, closeness, self-expression, liberty, love, practicality, stability, challenge, structure): universal behaviour aspects that reflect the desires that people aim to satisfy via their actions [13].
- **Personal Values** (Self-transcendence / Helping others; Conservation / Tradition; Hedonism / Taking pleasure in life; Self-enhancement / Achieving success; Open to change / Excitement): factors and principles that motivate an individual in life [14].

As the result, fifty-two personality characteristics in the form of their percentile scores were returned by this classifier and were further used in our analysis.

C. Results

The Personality Insights service returns a normalized score [0,1] as a percentile for each Big Five, Values, and Needs personality characteristic by comparing the raw score for the author's text with results from a sample population. Thus, a higher/lower score shows that a typical Twitter user who actively participates in the discussion of controversial Covid-19 treatment possesses the corresponding characteristic in a degree higher/lower than an average individual in the population, e.g. 0.8 means that 80% of the population has a lower score on the corresponding characteristic.

Boxplots on Figures 3-4 summarise typical users' personality profiles. Several oppositions in terms of personality traits can be noted. A typical user has high scores on *Extraversion*, *Neuroticism*, *Openness*. In terms of Big Five, typical users' scores on *Openness* are quite tight and tend to 1. The score on *Neuroticism* is also tight and has a median of 0.8, while *Extraversion* values are smasher. At the same time, we can observe tight values gravitating to 0 on *Conscientiousness* and *Agreeableness*. *Conscientiousness* is a person's tendency to act in an organized or thoughtful way. Conscientious people work hard to accomplish their goals and think carefully before acting. The median of our typical users in *Conscientiousness* is 0.1 meaning that most of the population are much more conscientious than the users involved in the discussion of the Covid-19 treatments. The low score on *Agreeableness* can be probably explained by a low level of trust to others. High score on *Neuroticism* corresponds to a high level on *Anger*, *Anxiety*, *Depression*, *Self-indulgence*, *Self-consciousness*, and *Sensitivity to stress*. Although these characteristics may be strengthened during the pandemic, we did not observe such high values in other groups [11].




Figure 3. Main personality profile of typical users

The tightest extreme values in terms of *Person's Needs* are *Structure* and *Curiosity*. Since the score on *Structure* is very low, our typical users do not exhibit groundedness nor they need things to be well organized and under control. In contrast, the extremely high score on *Curiosity* demonstrates a desire to discover, find out, and grow.

The value of *Conservation* corresponds to self-restriction, order, and resistance to change. Our typical users have an extremely low score in this facet while the *Openness to Change* showing a readiness for new experiences has values higher than in the population in general.

We further performed sentiment analysis of original tweets of typical users among 200 recent ones. Surprisingly, the proportion of *negative* tweets (orange) was less than *positive* ones (green) (see Figure 6). However, it should be noted that

most of the tweets were classified as being *neutral*, which may be due to the model used. Thus, among 16,038 analysed tweets, there were 2,438 negative, 8,784 neutral, and 4,816 positive tweets. The results of mean polarity of original tweets averaged per user are reported in Figure 5. It can be noted that the distributions of polarity value of positive and negative tweets are quite symmetrical, even though the negative polarities are more spread. Besides, the mean values of both categories are relatively low. Such results of sentiment analysis may be due to rather low expressiveness of typical users in terms of their linguistic means. The latter in its turn may be related to the analysed tweets as they are out of the scope of information cascades about COVID-19 treatments that polarised the Twitter community.




Figure 4. Facets of personality traits of typical users

Mean Polarity of Original Tweets of Typical Users by Polarity Category




Figure 5. Mean polarity of original tweets of typical users




Figure 6. Distribution of tweets of typical users w.r.t. polarity category

D. Discussion and Conclusion

Our results are consistent with descriptions of the behaviour in social media of the users who belong to specific psychological types. Our typical users are open-minded neurotics who are motivated to participate in the discussion by their need for curiosity and exhibit extravertive behaviour. The opposition between *Extraversion* and *Traditions* along with *Humility* is shown in [4]. Liu et al. [3] showed the impact of *Extraversion* and *Neuroticism* on the global use of social network sites: extraverts attracted and kept more friends than other users, they concentrated on communication with the friends; *Neuroticism* was associated with status update. Our typical users show both types of social media use. Based on the experiment studies and content analysis of texts produced by those who filled in questionnaires, Seegmiller and Epperson [5] distinguished sets of words that represent lexicons to define the personality profile according to Jungian typology. In [11], we showed that a user's choice of the words associated with *Thinking* or *Feeling* Jungian types corresponds to Big Five personality traits. Our participants of the Covid-19 treatment discussion have psychology traits of the *Thinking* type. The *Thinking* users who participated in information cascades reveal behaviour patterns associated with *Neuroticism* since they published a lot of original tweets that corresponds to the neurotics' typical action of frequent updates of their status on social media. In the current study, we show that they are persuasive in their argumentation offering positive texts. Thus, our typical participants of the general discussion of the COVID-19 treatment tend to score high on *Neuroticism* and its facets, *Openness*, and the need for *Curiosity*. They generally have low scores on *Conscientiousness*.

Reference List

1. Shmueli-Scheuer M. et al. Detecting Persuasive Arguments Based on Author-Reader Personality Traits and Their Interaction // Proceedings of the 27th ACM Conference on User Modeling, Adaptation and Personalization. New York, NY, USA: Association for Computing Machinery, 2019. P. 211–215.
2. Herzig J. et al. Predicting Customer Satisfaction in Customer Support Conversations in Social Media Using Affective Features // Proceedings of the 2016 Conference on User Modeling Adaptation and Personalization. New York, NY, USA: Association for Computing Machinery, 2016. P. 115–119.
3. Liu D., Campbell W.K. The Big Five personality traits, Big Two metatraits and social media: A meta-analysis // J. Res. Personal. 2017. Vol. 70. P. 229–240.
4. Cieciuch J., Schwartz S.H., Vecchione M. Applying the Refined Values Theory to Past Data: What Can Researchers Gain? // J. Cross-Cult. Psychol. SAGE Publications Inc, 2013. Vol. 44, № 8. P. 1215–1234.
5. Seegmiller R.A., Epperson D.L. Distinguishing Thinking-Feeling Preferences Through the Content Analysis of Natural Language // J. Pers. Assess. Routledge, 1987. Vol. 51, № 1. P. 42–52.

6. Boyd R.L. et al. Values in Words: Using Language to Evaluate and Understand Personal Values // ICWSM. 2015.
7. Marshall T.C. et al. Intellectual, narcissistic, or Machiavellian? How Twitter users differ from Facebook-only users, why they use Twitter, and what they tweet about. // Psychol. Pop. Media. US: Educational Publishing Foundation, 2020. Vol. 9, № 1. P. 14–30.
8. Lee K. et al. Who Will Retweet This? Automatically Identifying and Engaging Strangers on Twitter to Spread Information // Proceedings of the 19th International Conference on Intelligent User Interfaces. New York, NY, USA: Association for Computing Machinery, 2014. P. 247–256.
9. Mahmud J. et al. Optimizing the Selection of Strangers To Answer Questions in Social Media // CoRR. 2014. Vol. abs/1404.2013.
10. Oreg S., Sverdluk N. Source Personality and Persuasiveness: Big Five Predispositions to Being Persuasive and the Role of Message Involvement // J. Pers. 2014. Vol. 82, № 3. P. 250–264.
11. Nurbakova D., Ermakova L., Ovchinnikova I. Understanding the Personality of Contributors to Information Cascades in Social Media in response to the COVID-19 Pandemic // 2020 International Conference on Data Mining Workshops (ICDMW). 2020. P. 8. (In press)
12. Costa P., McCrae R. The revised NEO personality inventory (NEO-PI-R) // SAGE Handb. Personal. Theory Assess. 2008. Vol. 2. P. 179–198.
13. Kotler P.T., Armstrong G. Principles of Marketing. 15th ed. Prentice Hall, 2013.
14. Schwartz S. Basic human values: Theory, measurement, and applications // Rev. Fr. Sociol. 2006. Vol. 47. P. 929–968.
15. Carrillo-de-Albornoz J., Vidal J.R., Plaza L. Feature engineering for sentiment analysis in e-health forums // PLOS ONE. Public Library of Science, 2018. Vol. 13, № 11. P. e0207996.
16. Zunic A., Corcoran P., Spasic I. Sentiment Analysis in Health and Well-Being: Systematic Review // JMIR Med. Inform. JMIR Publications, 2020. Vol. 8, № 1. P. e16023–e16023.
17. Marianne Noel, Liana Ermakova, Pedro Rammaciotti, Alexis Perrier, and Bilel Benbouzid. 2020. Controverse scientifique. Available at: <https://dpa.hypotheses.org/controverse-scientifique>.

ЗНАЧЕНИЕ ТЕХНОЛОГИИ BLOCKCHAIN ДЛЯ ПОЗИТИВАЦИИ СМАРТ-КОНТРАКТА В УСЛОВИЯХ СОЗДАНИЯ НОРМАТИВНОГО РЕГУЛИРОВАНИЯ ЦИФРОВОЙ СРЕДЫ³¹

Захаркина Анна Владимировна

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, AnnaVladimirovna2009@yandex.ru

Статья посвящена экспресс-исследованию влияния технологии блокчейн на нормотворческую деятельность отечественного законодателя. Особое внимание в статье уделено проблеме позитивации смарт-контракта: ныне действующей редакции ч. 2 ст. 309 Гражданского кодекса РФ, а также вопросам, на которые предстоит ответить законодателю при будущей нормотворческой деятельности. Кроме того, в работе сделан акцент на цифровых новеллах российского гражданского права: цифровых правах, электронной форме сделки, электронной форме договора, «самоисполняющемся» обязательстве, краудфандинге, криптовалюте и цифровых финансовых активах. Обращено внимание на опосредованность практически всех цифровых новелл технологией блокчейн – информационной системой на основе распределенного реестра. Делается вывод о значительном экономическом потенциале технологии блокчейн, особенно в современных условиях тотальной утраты межличностного доверия.

Ключевые слова: смарт-контракт, блокчейн, информационная система, распределенный реестр, цифровые права, цифровые финансовые активы, гражданское право.

Еще в 2015 г., то есть пять лет назад, на Всемирном экономическом форуме, была озвучена революционная идея о том, что в 2027 г. объем мирового ВВП, основанного на технологии blockchain, достигнет 10 %. Очевидно, что сфера цифровых технологий обладает значительным экономическим потенциалом. Неудивительно в этой связи столь активное программное движение в этом направлении. Как известно, в Российской Федерации принят национальный проект «Национальная программа "Цифровая экономика Российской Федерации"». В структуре указанного проекта выделено шесть направлений развития, необходимых для реализации

31 Публикация подготовлена при финансовой поддержке гранта Президента РФ для государственной поддержки молодых российских ученых – кандидатов наук в рамках научного проекта МК-481.2020.6 «Позитивация смарт-контракта как нового института обязательственного права Российской Федерации, стимулирующего контрагентов к безопасному экономическому сотрудничеству, в условиях формирования нормативной платформы экосистемы цифровой экономики»

© Захаркина А.В., 2020

национальной программы: нормативное регулирование цифровой среды; информационная инфраструктура; кадры для цифровой экономики; информационная безопасность; цифровые технологии; цифровое государственное управление. Анализ всех перечисленных направлений показывает, что взаимодействие информационных технологий и всех сфер общественной жизни – это неизбежный процесс. Сейчас как никогда возрастает потребность в адаптации буквы закона к цифровому коду и наоборот. Создание нормативного регулирования цифровой среды – это длительный процесс, который требует постоянного обновления законодательства в той части, в которой оно не соответствует цифровым реалиям.

Интересно, что технология «блокчейн», обладая несравненными преимуществами по сравнению с аналогичными технологиями, проникает буквально во все сферы общественной жизни: от смарт-контрактов до сферы образования. Так, в Распоряжении Минпросвещения России от 18 мая 2020 г. № Р-44 «Об утверждении методических рекомендаций для внедрения в основные общеобразовательные программы современных цифровых технологий» обращается внимание на конкретные прикладные задачи, которые могут быть решены в образовательном учреждении с помощью технологии «блокчейн»: хранение школьных аттестатов, прочих общеобразовательных документов в базе данных; создание «динамических блоков курсов»; облачные базы знаний; цифровые сертификаты повышения квалификации.

Прежде всего, стоит обратиться к понятию технологии blockchain и ее преимуществам. В зарубежной научной литературе можно встретить значительное количество исследований на этот счет. К примеру, группа иностранных ученых в своем научном исследовании отмечает, что технология блокчейн опирается на криптографические правила, математику и теоретико-игровые стимулы для повышения доверия к операциям вычислительной системы [1]. Таким образом, основным преимуществом технологии блокчейн названо доверие, которое она обеспечивает между участниками системы. В сфере исполнения гражданско-правовых обязательств тема доверия стоит особенно остро. Распространенные случаи недобросовестного поведения, а также неисполнения или ненадлежащего исполнения гражданско-правовых обязательств приводят к утрате доверия между участниками имущественного оборота. Так, «акулами» рынка товаров, работ и услуг становятся крупные корпорации, к которым есть доверие. В результате такой ситуации выход на рынок субъектов малого и среднего бизнеса становится крайне затруднительным. Поэтому исполнение гражданско-правовых обязательств с помощью смарт-контрактов, существующих на платформе блокчейн, становится одной из актуальных задач, стоящих перед современным отечественным законодателем.

По справедливому замечанию итальянского ученого O. Konashevych, «применение блокчейна требует правильной архитектуры наложенных технологий для поддержки изменений устаревших и ошибочных данных,

решения вопросов цифровой идентификации и конфиденциальности, соблюдения законодательства и обеспечения исполнения смарт-контрактов, а также масштабируемости бухгалтерской книги» [2].

Как верно отмечает В.Б. Нагородская, «блокчейн работает для так называемых смарт-контрактов (т.е. "умных" контрактов), условия которых автоматически самоисполняются по наступлении заранее определенных обстоятельств» [3, с. 20]. Отметим, что ныне действующее гражданское законодательство не оперирует такими технологическими терминами как «смарт-контракт» или «блокчейн». Традиционно отечественный законодатель стремится к максимальной универсализации нормативных формулировок. В то же время считается, что необходимый для повсеместного использования технологии смарт-контрактов на платформе блокчейн корпус норм фактически создан. Так, Федеральным законом от 18 марта 2019 г. № 34-ФЗ «О внесении изменений в части первую, вторую и статью 1124 части третьей Гражданского кодекса Российской Федерации» ст. 309 Гражданского кодекса РФ (далее – ГК РФ) была дополнена частью второй следующего содержания: «Условиями сделки может быть предусмотрено исполнение ее сторонами возникающих из нее обязательств при наступлении определенных обстоятельств без направленного на исполнение обязательства отдельно выраженного дополнительного волеизъявления его сторон путем применения информационных технологий, определенных условиями сделки». Как видим, вместо термина «блокчейн» законодатель использует более широкое по своему содержанию понятие – «информационные технологии», однако такое решение подвергается обоснованной критике.

Оценивая норму ч. 2 ст. 309 ГК РФ, О.С. Гринь, Е.С. Гринь и А.В. Соловьев, замечают, что принятие обозначенной нормы права – это первый шаг к законодательной регламентации конструкции смарт-контракта в России [4]. Мы согласны с авторами в этом вопросе и полагаем, что действующей редакции ч. 2 ст. 309 ГК РФ для повсеместного внедрения технологии блокчейн в имущественный оборот очевидно недостаточно.

Стоит подчеркнуть, что ГК РФ и гражданское законодательство в целом постоянно «цифровизируется»: в нем появляются новеллы, необходимые для обеспечения нормативного регулирования цифровой среды. Так, с 1 октября 2019 г. появился новый объект гражданских прав – цифровые права (ст. 141.1 ГК РФ), новая форма сделки – с помощью электронных либо иных технических средств (п. 1 ст. 160 ГК РФ), новая форма договора – электронная (п. 2 ст. 434 ГК РФ), а также новый способ исполнения гражданско-правового обязательства – путем применения информационных технологий (ч. 2 ст. 309 ГК РФ). С 1 января 2020 г. был узаконен краудфандинг в результате принятия Федерального закона от 02 августа 2019 г. № 259-ФЗ (ред. от 20.07.2020) «О привлечении инвестиций с использованием инвестиционных платформ и о внесении изменений в отдельные законодательные акты Российской Федерации»), Наконец, с 1 января 2021 г. вступит в силу Федеральный закон от 31 июля 2020 г. № 259-

ФЗ «О цифровых финансовых активах, цифровой валюте и о внесении изменений в отдельные законодательные акты Российской Федерации» (далее – Закон о ЦФА). Столь активная правотворческая деятельность законодателя свидетельствует о понимании экономического потенциала цифровых ресурсов. Заметим, что в основе большинства из перечисленных легализованных цифровых явлений лежит именно технология блокчейн, которая сама по себе остается за рамками правового регулирования. Как мы уже отмечали, законодатель не использует термин «блокчейн», однако очевидно, что этот термин подразумевается под словосочетанием «информационная система на основе распределенного реестра». Так, указанное словосочетание фигурирует в новом Законе о ЦФА: под цифровыми финансовыми активами предложено понимать цифровые права, «выпуск, учет и обращение которых возможны только путем внесения (изменения) записей в информационную систему на основе распределенного реестра». Стало быть, осуществление цифровых прав вне информационной системы на основе распределённого реестра становится невозможным. В этом смысле ранее существовавшее доверие к человеку сменяется доверием к информационной системе, которая независима, беспристрастна и предсказуема.

Возвращаясь к центральному вопросу настоящего микроисследования – значению технологии блокчейн для позитивации смарт-контракта в условиях создания нормативного регулирования цифровой среды, отметим следующее. Понимание технологии блокчейн является неотъемлемым условием успешной нормотворческой работы отечественного законодателя. Новеллизируя нормы о смарт-контракте, законодатель должен исходить из технических достоинств и недостатков технологии блокчейн. Как известно, при всех несомненных преимуществах, эта технология также уязвима. К примеру, в правовом поле достаточно остро стоят следующие вопросы:

1) Как обеспечить восприимчивость смарт-контракта к императивным нормам-принципам гражданского права и оценочным категориям (справедливость, разумность, добросовестность)?

2) Как создать условия для универсализации смарт-контракта, при которых сфера его практического применения выйдет за рамки сугубо предпринимательских отношений и станет актуальной и для отношений с участием потребителя?

3) Как защитить участников смарт-контракта от кибератак и прочих незаконных вмешательств?

Таким образом, полагаем, что при создании нормативного регулирования цифровой среды важно использовать междисциплинарное взаимодействие представителей информационных и юридических наук. Так, для надлежащего исполнения гражданско-правового обязательства при помощи смарт-контракта важно «перевести» язык гражданско-правового договора на язык программирования. В этом процессе участие программиста и юриста неизбежно. Полагаем, что технология блокчейн станет основой всех легализованных на сегодняшний день цифровых явлений: смарт-

контрактов, цифровых финансовых активов, т.е. цифровых прав, в том числе утилитарных цифровых прав, криптовалюты и т.д.

Библиографический список

1. *De Filippi, Primavera, Mannan, Morshed, Reijers Wessel*. Blockchain as a confidence machine: The problem of trust & challenges of governance // TECHNOLOGY IN SOCIETY. 2020. Vol. 62. Number of Article 101284.
2. *Konashevych O*. Constraints and benefits of the blockchain use for real estate and property rights // JOURNAL OF PROPERTY PLANNING AND ENVIRONMENTAL LAW. 2020. DOI: 10.1108/JPEL-12-2019-0061.
3. *Нагородская В.Б.* Новые технологии (блокчейн / искусственный интеллект) на службе права: научно-методическое пособие / под ред. Л.А. Новоселовой. М.: Проспект, 2019. 128 с.
4. *Гринь О.С., Гринь Е.С., Соловьев А.В.* Правовая конструкция смарт-контракта: юридическая природа и сфера применения // Lex russica. 2019. № 8. С. 51–62.

THE VALUE OF BLOCKCHAIN TECHNOLOGY FOR SMART CONTRACT ACTIVATION IN THE CONTEXT OF CREATING A REGULATORY ENVIRONMENT FOR THE DIGITAL ENVIRONMENT

Zakharkina Anna V.

Perm State University, 15, Bukireva st., Perm, 614990, Russia,
AnnaVladimirovna2009@yandex.ru

The article is devoted to an Express study of the impact of blockchain technology on the rule-making activities of domestic legislators. Special attention is paid to the problem of smart contract positivation: the current version of part 2 of article 309 of the Civil code of the Russian Federation, as well as questions that the legislator will have to answer in future rule-making activities. In addition, the paper focuses on digital novelties of Russian civil law: digital rights, electronic transaction form, electronic contract form, "self-fulfilling" obligation, crowdfunding, cryptocurrency and digital financial assets. Attention is drawn to the mediation of almost all digital novelties by the blockchain technology-an information system based on a distributed registry. The conclusion is made about the significant economic potential of blockchain technology, especially in modern conditions of total loss of interpersonal trust.

Key words: smart contract, blockchain, information system, distributed registry, digital rights, digital financial assets, civil law.

ПРОГРАММА ВЫБОРА ПАРЕТО-ОПТИМАЛЬНЫХ РЕШЕНИЙ ДЛЯ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ

Иванова Ксения Михайловна

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
ivanovaksenijamikh@yandex.ru

ПАО «Пермская научно-производственная приборостроительная компания»,
614990, Россия, г. Пермь, ул. 25 Октября, д. 106

В статье описана предлагаемая программа, осуществляющая поиск Парето-оптимальных вариантов выбора альтернатив для интеллектуальной системы (ИС) принятия решений. Программа разработана на языке программирования C++. Модели альтернатив вводятся в систему с помощью соответствующих формализаций. После этого формируются комбинации альтернатив, которые оцениваются с помощью заданных различных показателей и далее формируется множество Парето, которое выводится в блок принятия решений, а графическое представление в блок вывода данных.

Ключевые слова: Парето-оптимальное решение, C++, комбинации альтернатив.

Введение

Появление роботов и систем с элементами искусственного интеллекта (СЭИИ) становится неотъемлемой частью нашей повседневной жизни [1]. Возникло даже направление моделирования эмоций роботов [2]. Экспертные системы, основанные на процедуре логического вывода, разрабатываются с 70-х годов XX века. Именно для этого и был создан язык ПРОЛОГ [3]. Широкую известность в свое время получили шахматные поединки в том числе нашего гроссмейстера Г. Каспарова с суперкомпьютером Deep Blue, использующим поиск по дереву решений [4]. Однако задачи принятия сложных многокритериальных решений СЭИИ до сих пор в полной мере не решены [5]. Распространённым способом решения этой проблемы является поиск множества Парето-оптимальных решений, который представляет собой подбор комбинаций всевозможных альтернатив, из которых затем выбирается лучшая альтернатива [6-9].

В предложенной статье описывается разработанная программа поиска Парето-оптимальных вариантов выбора альтернатив для поддержки принятия решений СЭИИ.

Входные параметры из ИС

Пусть задано абстрактное множество M

$$M = \{m_i\}_{i=1,n}, \quad (1)$$

где $m_i, i = 1, n$ – альтернативы действий, и множество P

$$P = \{p_j\}_{j=1,k}, \quad (2)$$

где $p_j, j = 1, k$ – параметры качества.

Множества M и P связаны матрицей формул F , имеющей вид:

$$F = \begin{pmatrix} f_{11}(x_1, \dots, x_{l_1}) & \dots & f_{1k}(x_1, \dots, x_{l_k}) \\ \dots & \dots & \dots \\ f_{n1}(x_1, \dots, x_{l_1}) & \dots & f_{nk}(x_1, \dots, x_{l_k}) \end{pmatrix} \quad (3)$$

где $\{f_{ij}(x_1, \dots, x_{l_i})\}_{i=1,n, j=1,k}$ – формулы оценок параметров качества, $n = |M|, k = |P|$. Таким образом, каждой альтернативе $m_i \in M, i = 1, n$ ставится в соответствие подмножество формул $F \supset F_i = \{f_{ij}(x_1, \dots, x_{l_i})\}_{i=1,n, j=1,k}$.

Множество альтернатив M (1), множество параметров качества P (2), матрица формул оценок F (3) и необходимые количественные величины, поступают в программу от интеллектуальной системы с помощью соответствующих формализаций.

Реализация программы

Схема взаимодействия программы и ИС представлена на рис. 1.

Как только в программу поступили необходимые параметры от ИС, запускается выполнение алгоритма нахождения множества Парето. Алгоритм состоит из трех этапов.

Первый этап – формирование комбинаций альтернатив. По данному множеству альтернатив M (1) формируется множество всевозможных комбинаций альтернатив S , такое что, количество альтернатив входящих в каждый элемент $s \in S$ ограничено заданной величиной.

Второй этап – вычисление всевозможных решений. По полученному, в первом этапе, множеству S , для каждого элемента $s \in S$, состоящего из комбинации альтернатив $m_j \in M, j = 1, N$, где N – количественная величина ограничения, вычисляются значения параметров качества $p_i \in P, i = 1, |P|$ по формулам, заданным матрицей (3) и записываются в таблицу 1.




Рис. 2. Схема взаимодействия программы и ИС

Таблица 1 – Всевозможные решения для множества комбинаций альтернатив

Комбинации альтернатив	Параметры качества P			
	p_1	p_2	...	p_n
$c_1 : N \cdot m_1$	s_{11}	s_{12}	...	s_{1n}
$c_2 : N \cdot m_2$	s_{21}	s_{22}	...	s_{2n}
...
$c_i : (N - 1) \cdot m_1 + m_2$	s_{i1}	s_{i2}	...	s_{in}
...
$c_k : \sum_{l=1}^N m_l$	s_{k1}	s_{k2}	...	s_{kn}

Элементы множества всевозможных решений $S = \{s_{ij}\}_{i=1,k,j=1,n}$ вычисляются по следующей формуле (4):

$$s_{ij} = \sum_{t=1}^r a_t \cdot f_{ij}, \quad (4)$$

где a_t – коэффициент при альтернативе m_t из комбинации c_i , r – количество различных альтернатив в комбинации c_i , f_{ij} – формулы оценок матрицы (3), $i = 1, k$, $j = 1, n$.

Третий этап – поиск множества Парето. По вычисленной таблице всевозможных решений второго этапа, происходит поиск Парето-оптимального множества с использованием частных целевых функций для каждого из параметров качества.

После завершения третьего этапа работы алгоритма программы, сформированное множество Парето поступает в блок принятия решений ИС, а графическое представление полученных данных в блок вывода (рис. 2).




Рисунок 2. Отображение множества Парето в блоке вывода

Вывод

Время и память, потребляемые при выполнении алгоритма поиска Парето-оптимального множества, зависят прямо пропорционально от мощности множества альтернатив, количества параметров качества и сложности формул оценок. Наиболее затратный по времени этап – вычисление всевозможных решений, т.к. происходит выполнение большого количества арифметических операций.

Разработанная программа позволяет находить Парето-оптимальное решение для интеллектуальной системы. Применение этой программы позволит освободить ИС от «рутинной» работы, т.е. предоставить ИС уже готовый результат для принятия решения.

Библиографический список

1. Макаров И. М. и др. Искусственный интеллект и интеллектуальные системы управления. – 2006.
2. Пенский О.Г. Математические модели эмоциональных роботов: монография. Пермь: изд-во Перм. гос. ун-та, 2010 – 192 с.
3. Pereira F. C. N., Shieber S. M. Prolog and natural-language analysis. – Microtome Publishing, 2002.
4. Campbell M., Hoane Jr A. J., Hsu F. Deep blue //Artificial intelligence. – 2002. – Т. 134. – №. 1-2. – С. 57-83.
5. Лотов А. В. и др. Компьютер и поиск компромисса. Метод достижимых целей //М: Издательство «Наука». – 1997.
6. Mishra S. K. et al. A fast multiobjective evolutionary algorithm for finding wellspread pareto-optimal solutions //In KanGAL Report No. 2003002, Indian Institute Of Technology Kanpur. – 2002.
7. Deb K., Gupta H. Searching for robust Pareto-optimal solutions in multi-objective optimization //International conference on evolutionary multi-criterion optimization. – Springer, Berlin, Heidelberg, 2005. – С. 150-164.
8. Baykasoglu A., Owen S., Gindy N. A taboo search based approach to find the Pareto optimal set in multiple objective optimization //Engineering Optimization. – 1999. – Т. 31. – №. 6. – С. 731-748.
9. Подиновский В. В., Ногин В. Д. Парето-оптимальные решения многокритериальных задач. – Физматлит, 2007.

PROGRAM TO SELECT FOR PARETO-OPTIMAL SOLUTIONS FOR AN INTELLIGENT SYSTEM

Ivanova Ksenya M.

Perm National Research Politechnical University,
614990, Russia, Perm, Komsomolsky Av. 29,
ivanovaksenijamikh@yandex.ru

JSC «Perm Scientific-Industrial Instrument Making Company»,
614990, Russia, Perm, 25th October St, 106

The article describes the proposed program that searches for Pareto-optimal options for choosing alternatives for an intelligent decision-making system. The program is developed in the C ++ programming language. Models of alternatives are introduced into the system using appropriate formalizations. After that, combinations of alternatives are formed, which are evaluated using specified various indicators, and then a Pareto set is formed, which is displayed in the decision-making block, and a graphical representation in the data output block.

Key words: Pareto-optimal solution, C++, combinations of alternatives.

ПРИМЕНЕНИЕ АДДИТИВНЫХ ТЕХНОЛОГИЙ ДЛЯ СТРОИТЕЛЬНОЙ ПРОМЫШЛЕННОСТИ

Иванов Илья Борисович, Духанин Алексей Владиславович

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
cot1884@gmail.com

В статье рассматриваются современные возможности аддитивных технологий для применения в строительной промышленности, а также оцениваются основные преимущества строительства с применением аддитивных технологий перед стандартными способами строительства. Также анализируются различные методы печати путём аддитивных технологий, среди которых способ напыления (лазерная стереолитография), послойно посредством луча происходит печать деталь в специальной ванне, наполненной раствором. Также рассматриваются основные принципы аддитивных технологий, где деталь в отличие от устоявшейся технологии, в которой от заготовки отсекается или вытачивается всё лишнее, проходит полный путь от модели, нарисованной в САПР, и последующим её печати на трёхмерном принтере, посредством послойной печати филамента.

Ключевые слова: аддитивные технологии, строительная промышленность, 3D-печать, FDM, экструдирование, лазерное стереолитография.

Строительство играет важную роль, как в развитии экономики, так и комфорте населения[1]. В ней задействовано рекордное количество рабочих мест, как в отдельно взятой стране, так и во всем мире. В то же время технологии не стоят на месте и готовят данную отрасль к значительной трансформации. Будут изменения проходить плавно и займёт существенное количество времени, но, тем не менее, и в типовом, и в индивидуальном строительстве постепенно начинают применяться новые материалы, которые включают в себя повышенный комфорт, экологичность и экономичность при эксплуатации. Происходит внедрение новых технологий, позволяющие автоматизировать большую часть процесса воплощения проектов в реальность, со значительным сокращением количества необходимой рабочей силы, а также минимизацией риска производственных травм. Одной из таких перспективных технологий является применение аддитивной технологии строительства зданий при помощи 3D-печати на строительных площадках. 3D-печать архитектурных сооружений вызывает большой интерес специалистов уже несколько лет. С появлением строительного 3D-принтера теперь есть возможность создавать не только маленькие детали и

конструкции (строительных блоков, малых элементов ландшафтного дизайна и интерьера помещений), но и возводить ограждающие конструкции зданий.

Строительство с использованием технологии 3D-печати почти схожи со стандартным возведением зданий и сооружений. Начинается всё с составлением общей концепции здания или сооружения, создания рабочего проекта и выборки материалов. Первые этапы строительства могут использовать компьютерное моделирование. Чтобы создать определённую конструкцию требуется грамотный подбор состава бетонной смеси, на основе которой будут создаваться, например, несущие стены и пол[2]. Современные аддитивные технологии могут создавать всевозможные по форме сооружения и дополнять этапы строительства изоляционными и отделочными работами.

Основные плюсы использования аддитивных технологий[3]:

Экономическая целесообразность – сокращение временных, рабочих и материальных затрат.

С заботой об окружающей среде – минимум отходов, в следствие чего, более благоприятные последствия для экологии.

Архитектурная свобода – можно возвести здание любой формы и размеров, в зависимости от используемого оборудования.

Точность и качество – печать, ведется строго по проекту с максимальной точностью, что может выдать компьютер.

Скорость строительства- оборудование работает чётко с заданной скоростью без перерывов и выходных.

Контурная технология печати стала использоваться не так давно. Первые попытки были сделаны Китаем в 2014 году. Продвижением аддитивных технологий стали активно заниматься многие страны. Национальные ассоциации по аддитивным технологиям, объединены в альянс Global Alliance of Rapid Prototyping Associations, где люди делятся технологиями, создавая, продавая права на их дальнейшее использование и привлекая к работе фирмы разработчики трёхмерных моделей. Но широкое применение данная технология получила пока лишь США, Японии, Германии и Китае. Лидирующие позиции в данной отрасли получила компания 3D-Systems.

Модернизация цифровых технологий, на протяжении многих лет, привели к идеи послойного создания объектов с использованием трёхмерного принтера с помощью заранее подготовленной математической моделью. Технология нанесения материала на основу назвали аддитивной. При использовании традиционного производства подобных объектов, мы изначально имеем заготовку, от которой, например, удаляем все лишнее, или деформируем ее, но с аддитивной технологией из аморфного расходного материала создаётся изделие. История объёмной печати начинается с 1948 года, в Америке, когда у Чарльза Халли возникла идея послойного создания объектов из ФПК- фотополимеризующейся композиции. Технологию назвали STL «стереолитографии». В 1986 году, автор получил патент основал компанию 3D System, где начал создавать первые промышленные устройства для трёхмерной печати. В 1987 был представлен рабочий образец. Машина

выращивала объект из жидкой фотополимеризующейся композиции, нанося её послойно на платформу, опускающуюся в ванну с ФПК, по инструкции, заложенную в вычислительную машину. Толщина слоя при этом составляла около 0,1-0,2 мм. В 1988 году Скотт Крамп запатентовал технологию 3D-печати с помощью послойной заливки доведенной до расплавленного состояния полимера (FDM). В специальной печатающей головке материал плавится под действием высоких температур и поступает в рабочую камеру. Из сопла выходит расплавленный полимер в виде нити, которую по математической модели кладут на рабочую поверхность. Далее платформа опускается ниже на один слой и повторяет искомый процесс. Первое коммерческое устройство на основе технологии FDM увидело свет в 1991 году под торговой маркой Stratasys. В начале XXI века сразу учёные из разных стран активно, начали изучать область аддитивных технологий в строительстве. В 2012 году выпущены первые строительные 3D-принтеры для обычного потребителя, через два года, после этого, в Китае был возведен первый экспонат одноэтажного жилья компанией Shanghai WinSun.

Для создания объектов промышленности, машиностроения, пищевого производства и других отраслей, существует множество способов 3D-печати: лазерная стереолитография, селективное лазерное спекание, моделирование методом наплавления, ламинирование, склеивание порошков. При печати малых форм и целых объектов строительства используются три основных метода: спекание; лазерная стереолитография, послойное экструдирование.

Строительство играет важную роль, как в развитии экономики, так и комфорте населения[1]. В ней задействовано рекордное количество рабочих мест, как в отдельно взятой стране, так и во всем мире. В то же время технологии не стоят на месте и готовят данную отрасль к значительной трансформации. Будут изменения проходить плавно и займёт существенное количество времени, но, тем не менее, и в типовом, и в индивидуальном строительстве постепенно начинают применяться новые материалы, которые включают в себя повышенный комфорт, экологичность и экономичность при эксплуатации. Происходит внедрение новых технологий, позволяющие автоматизировать большую часть процесса воплощения проектов в реальность, со значительным сокращением количества необходимой рабочей силы, а также минимизацией риска производственных травм. Одной из таких перспективных технологий является применение аддитивной технологии строительства зданий при помощи 3D-печати на строительных площадках. 3D-печать архитектурных сооружений вызывает большой интерес специалистов уже несколько лет. С появлением строительного 3D-принтера теперь есть возможность создавать не только маленькие детали и конструкции (строительных блоков, малых элементов ландшафтного дизайна и интерьера помещений), но и возводить ограждающие конструкции зданий.

Строительство с использованием технологии 3D-печати почти схожи со стандартным возведением зданий и сооружений. Начинается всё с составлением общей концепции здания или сооружения, создания рабочего проекта и выборки материалов. Первые этапы строительства могут

использовать компьютерное моделирование. Чтобы создать определённую конструкцию требуется грамотный подбор состава бетонной смеси, на основе которой будут создаваться, например, несущие стены и пол[2]. Современные аддитивные технологии могут создавать всевозможные по форме сооружения и дополнять этапы строительства изоляционными и отделочными работами.

Основные плюсы использования аддитивных технологий[3]:

Экономическая целесообразность – сокращение временных, рабочих и материальных затрат.

С заботой об окружающей среде – минимум отходов, в следствие чего, более благоприятные последствия для экологии.

Архитектурная свобода – можно возвести здание любой формы и размеров, в зависимости от используемого оборудования.

Точность и качество – печать, ведется строго по проекту с максимальной точностью, что может выдать компьютер.

Скорость строительства- оборудование работает чётко с заданной скоростью без перерывов и выходных.

Контурная технология печати стала использоваться не так давно. Первые попытки были сделаны Китаем в 2014 году. Продвижением аддитивных технологий стали активно заниматься многие страны. Национальные ассоциации по аддитивным технологиям, объединены в альянс Global Alliance of Rapid Prototyping Associations, где люди делятся технологиями, создавая, продавая права на их дальнейшее использование и привлекая к работе фирмы разработчики трёхмерных моделей. Но широкое применение данная технология получила пока лишь США, Японии, Германии и Китае. Лидирующие позиции в данной отрасли получила компания 3D-Systems.

Модернизация цифровых технологий, на протяжении многих лет, привели к идеи послойного создания объектов с использованием трёхмерного принтера с помощью заранее подготовленной математической моделью. Технология нанесения материала на основу назвали аддитивной. При использовании традиционного производства подобных объектов, мы изначально имеем заготовку, от которой, например, удаляем все лишнее, или деформируем ее, но с аддитивной технологией из аморфного расходного материала создаётся изделие. История объёмной печати начинается с 1948 года, в Америке, когда у Чарльза Халли возникла идея послойного создания объектов из ФПК- фотополимеризующейся композиции. Технологию назвали STL «стереолитографии». В 1986 году, автор получил патент основал компанию 3D System, где начал создавать первые промышленные устройства для трёхмерной печати. В 1987 был представлен рабочий образец. Машина выращивала объект из жидкой фотополимеризующейся композиции, нанося её послойно на платформу, опускающуюся в ванну с ФПК, по инструкции, заложенную в вычислительную машину. Толщина слоя при этом составляла около 0,1-0,2 мм. В 1988 году Скотт Крамп запатентовал технологию 3D печати с помощью послойной заливки доведенной до расплавленного состояния полимера (FDM). В специальной печатающей головке материал

плавится под действием высоких температур и поступает в рабочую камеру. Из сопла выходит расплавленный полимер в виде нити, которую по математической модели кладут на рабочую поверхность. Далее платформа опускается ниже на один слой и повторяет искомый процесс. Первое коммерческое устройство на основе технологии FDM увидело свет в 1991 году под торговой маркой Stratasys. В начале XXI века сразу учёные из разных стран активно, начали изучать область аддитивных технологий в строительстве. В 2012 году выпущены первые строительные 3D-принтеры для обычного потребителя, через два года, после этого, в Китае был возведен первый экспонат одноэтажного жилья компанией Shanghai WinSun.

Для создания объектов промышленности, машиностроения, пищевого производства и других отраслей, существует множество способов 3D-печати: лазерная стереолитография, селективное лазерное спекание, моделирование методом наплавления, ламинирование, склеивание порошков. При печати малых форм и целых объектов строительства используются три основных метода: спекание; лазерная стереолитография, послойное экструдирование.

Идея способа спекания (селективное спекание) в том, что рабочие чернила, к примеру, кварцевый песок, расплавляются за счет действия точечного лазерного луча, направление траектории которого приводится в действие с помощью кулачкового механизма. Механизм перемещения обрабатываемого материала приводится в движение небольшим двигателем, запускающим движение зубчатого ремня привода распределительного вала. Одновременно сфокусированная шаровая линза насквозь прожигает материал, находящийся под ней. Производством данного оборудования занимается его изобретатель, инженер Маркус Кайзер.

Чтобы использовать способ напыления (лазерная стереолитография) используется лазерная установка с ванной, оборудованная специальным столом. Ванна заполняется жидкий фотополимеризующейся под воздействием лазерного луча композицией. Спекание материала происходит послойно, с помощью перемещения лазерного луча по намеченной траектории. Во время завершения обработки первого слоя стол ванны опускается на шаг, после чего выполняется формирование следующего слоя.

Способы напыления и селективного спекания являются экологически безвредными, поскольку их реализация подразумевает использование солнечной энергии, а рабочей смесью является песок.

Способ послойного экструдирования на данный момент является часто используемым видом 3D-печати большинства строительных принтеров используемых во всём мире. Идея состоит в том, что рабочее сопло, или экструдер, трёхмерного принтера выпускает быстротвердеющую бетонную смесь, где используются различные добавки, чтобы улучшить характеристики будущей конструкции. Все последующие слои выдавливаются 3D-принтером поверх предыдущего, благодаря чему формируется определенная конструкция

Внедрение аддитивных технологий в строительстве сооружений при помощи 3D-технологий имеет множество положительных моментов по

сравнению со стандартными методами. Несомненными преимуществами аддитивной технологии является снижение трудоемкости работ, риска производственного травматизма, повышение автоматизации и скорости строительства, снижение отходов производства

Успешное толчком на пути популяризации использования аддитивной технологии с применением строительного трёхмерного принтера требует комплексных исследований направленных на разработку эффективных композитов нового поколения с требуемыми изменяемыми в зависимости от потребностей свойствами.

Библиографический список

1. Мухаметрахимов Р. Х., Вахитов И.М., Аддитивная технология возведения зданий и сооружений с применением строительного 3D-принтера, Известия КГАУ, 2017.
2. Пермяков М.Б., Пермяков А.Ф., Давыдова А.М. Аддитивные технологии в строительстве // European Research. 2017. №1 (24). С. 14-15.
3. Дребезгова М.Ю., Современные аддитивные технологии в малоэтажном строительстве, Вестник БГТУ им.В.Г. Шухова, 2017, №6.

APPLICATION OF ADDITIVE TECHNOLOGIES FOR THE CONSTRUCTION INDUSTRY

Ivanon Ilya B., Duhanin Aleksei V.
State National Research Politechnical University of Perm,
614000, Russia, Perm, Komsomolsky Av. 29,
cot1884@gmail.com

The article examines the modern possibilities of additive technologies for use in the construction industry, and also evaluates the main advantages of construction using additive technologies over standard construction methods. Various methods of printing by means of additive technologies are also analyzed, including the method of spraying (laser stereolithography), the part is printed layer by layer by means of a beam in a special bath filled with a solution. The basic principles of additive technologies are also considered, where the part, in contrast to the established technology, in which everything unnecessary is cut off or machined from the workpiece, goes all the way from the model drawn in the CAD, and then printing it on a three-dimensional printer, by means of layer-by-layer printing of the filament.

Key words: additive technologies, construction industry, 3D printing, FDM, extrusion, laser stereolithography.

ОЦЕНКА ЭФФЕКТИВНОСТИ ПОДКРЕПЛЯЮЩИХ ЭЛЕМЕНТОВ В ЗАДАЧЕ ОПТИМИЗАЦИИ КОМПОЗИТНОЙ ПЛАСТИНЫ

Кусяков Альфред Шамильевич

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, *kusyakov@psu.ru*

Исследуется проблема оптимизации подкрепленной композитной пластинки, находящейся под действием сжимающих в плоскости пластинки нагрузок. Целевой функцией служит масса конструкции. При построении физических ограничений учитываются условия устойчивости и прочности. Большинство из известных к настоящему времени алгоритмов оптимизации основаны на предположении, что решение задачи существует и единственно. В данной работе предлагается алгоритм оптимизации подкрепленной пластины, позволяющий учесть не только множественность, но и отсутствие решения задачи оптимизации. Приведены численные результаты, позволяющие оценить эффективность введения в конструкцию композитной пластины подкрепляющих элементов.

Ключевые слова: оптимизация; композит; пластина; ребра жесткости, устойчивость; прочность.

Введение

В задачах оптимального проектировании композитных конструкций возможны различные формулировки проблемы оптимизации. Различия заключаются в выборе критерия оптимальности. В задачах проектирования тонкостенных композитных конструкций, как правило, в качестве критерия оптимальности принимается минимум массы конструкции при различных ограничениях, наложенных на проект (структурных, геометрических и физических). Модель оптимизации композитной конструкции может быть представлена следующими элементами: \bar{x} – искомый вектор варьируемых параметров (толщина оболочки, относительные содержания слоев определенного типа и т.д.); $G(\bar{x})$ – целевая функция (масса конструкции); D – область, определяемая наложенными на проект ограничениями. Задача оптимизации формулируется следующим образом: найти минимум функции $G(\bar{x})$ для всех $\bar{x} \in D$. Результаты исследований в данной области достаточно полно представлены, например, в работах [1–7]. Основное внимание в указанных работах уделялось вопросам разработки алгоритмов оптимального проектирования, в предположении, что решение задачи существует и единственно. В статье [8] приведен алгоритм оптимизации подкрепленной пластины, позволяющий находить все решения задачи оптимизации, в предположении, что решение задачи существует. Показано, что задача

оптимизации может иметь более одного решения. В настоящей работе предлагается модифицированный алгоритм решения задачи оптимизации подкрепленной пластины, позволяющий учесть не только множественность, но и отсутствие решения задачи.

Постановка задачи

Многослойная пластинка длиной a и шириной b , подкрепленная регулярным набором продольных ребер (стрингеров), находится под действием сжимающих нагрузок q (см. рис. 1).




Рисунок 1. Стрингерная пластинка

Требуется оценить эффективность использования ребер в конструкции пластины по сравнению с неподкрепленной пластиной.

Введем обозначения: ρ_0 – плотность материала пластины; h – толщина пластинки; t_s, H_s, B_s – шаг, высота и ширина продольного ребра соответственно; $h_s = \frac{B_s H_s}{t_s}$ – условная толщина стрингеров; $h_f = h + h_s$ –

полная условная толщина подкрепленной пластины; $\gamma = \frac{h}{h_f}$ – относительная

толщина полотна пластинки; H_{sm} – максимально допустимая по условиям технологии высота стрингеров; $b_{11}, b_{22}, b_{12}, b_{33}$ – компоненты матрицы жесткости монослоя.

Алгоритм оптимизации

Общий алгоритм решения данной задачи, в предположении, что решение существует, представлен в работе [8]. Модифицированный алгоритм решения задачи оптимизации, учитывающий возможность отсутствия решения, состоит из следующих шагов:

1. Полагаем, что полотно подкрепленной пластины состоит только из продольных монослоев.

2. По известной величине сжимающей нагрузки и пределу прочности материала пластинки при сжатии, находим полную условную толщину h_f подкрепленной пластины:

$$h_f = \frac{q_0}{\sigma_{-lv}}.$$

Здесь σ_{-lv} – предел прочности монослоя при сжатии в направлении волокон, q_0 – заданная сжимающая нагрузка.

3. Полагая $h = h_f$, находим критическую нагрузку для гладкой пластинки

$$q_f = D_f \left(\frac{\pi}{a} \right)^2,$$

где $D_f = \frac{b_{11} h_f^3}{12}$ – изгибная жесткость пластинки.

Проверяем выполнение условия устойчивости:

$$q_f \geq q_0.$$

Если это условие выполняется, то процесс проектирования завершается. Введение в конструкцию пластины подкрепляющих элементов не позволяет снизить массу конструкции.

Если условие общей устойчивости не выполняется, тогда вычисляем максимально возможную по условиям устойчивости толщину гладкой пластины

$$h_{\max} = \left(\frac{12q_0}{b_{11}} \left(\frac{a}{\pi} \right)^2 \right)^{\frac{1}{3}}.$$

Находим теоретический коэффициент снижения массы $k_{ilm} = \frac{h_f}{h_{\max}}$.

4. Полагая $k_{lm} = k_{ilm}$, $h_f = k_{lm} h_{\max}$, решаем уравнение устойчивости [8]

$$\gamma^3 + (1 - \gamma)r_H^2 + 3\gamma(1 - \gamma)(r_H + \gamma)^2 = \frac{q_0}{q_f},$$

где $r_H = \frac{H_{sm}}{h_f}$.

Если уравнение имеет решения на промежутке $[0; 1]$, переходим к следующему шагу. В противном случае, определяем на промежутке $[k_{ilm}; 1]$ наименьшее возможное значение коэффициента k_{ilm} , при котором уравнение устойчивости имеет решение. Для нахождения коэффициента k_{ilm} можно воспользоваться, например, методом половинного деления.

5. По найденным значениям относительной толщины γ и полной условной толщины пластины h_f вычисляем толщину полотна и условную толщину ребер соответственно

$$h = h_f \gamma, \quad h_s = h_f (1 - \gamma).$$

6. Шаг продольных ребер находим из условия сохранения местной устойчивости [8]

$$t_s = \pi \gamma \sqrt{\frac{\sqrt{b_{11} b_{22}} + b_{12} + 2b_{33}}{6q_0}} h_f^3.$$

7. По найденной полной условной толщине подкрепленной пластины находим массу подкрепленной конструкции.

$$G = 2ab\rho_0 h_f.$$

Оценим эффективность использования ребер в конструкции пластины по сравнению с неподкрепленной пластиной для следующих исходных данных: $b_{11} = 161$ ГПа; $b_{22} = 7,84$ ГПа; $b_{12} = 2,67$ ГПа; $b_{33} = 4,40$ ГПа;

$$\sigma_{-iv} = 1,6 \text{ ГПа}; \rho_0 = 1500 \frac{\text{кг}}{\text{м}^3}; q_0 = 2 \cdot 10^5 \text{ Н/м}; a = 1 \text{ м}; b = 3 \text{ м}; H_{sm} = 0,02 \text{ м}.$$

В результате расчетов получено следующее значение теоретического коэффициента снижения массы: $k_{tm} = 0,01$. Соответствующее значение полной условной толщины равно $h_f = 1,25 \cdot 10^{-4}$ м. Подставив найденное значение полной условной толщины в уравнение устойчивости, получим, что данное уравнение не имеет допустимых действительных корней (уменьшить массу исходной конструкции в 100 раз невозможно). Наименьшее допустимое значение коэффициента снижения массы, полученное методом половинного деления, получается равным $k_{tm} = 0,6$. Соответствующее значение полной условной толщины равно $h_f = 0,69 \cdot 10^{-2}$ м. Таким образом, введение в конструкцию пластины подкрепляющих элементов позволяет снизить массу конструкции на 40 процентов.

Подставив найденное значение h_f в уравнение устойчивости получим, что данное уравнение имеет два корня: $\gamma_1 = 0,43$ и $\gamma_2 = 0,49$. Полученные значения относительных толщин полотна позволяют определить толщины полотна, условные толщины ребер, расстояния между ребрами, а также массу подкрепленной пластины. Соответствующие формулы приведены выше.

В заключение отметим, что предлагаемый алгоритм позволяет не только преодолеть трудности, связанные с отсутствием решений задачи оптимизации, но и оценить возможность снижения массы конструкции до заданного уровня. В последнем случае проверяется наличие допустимых корней уравнения устойчивости при заданном коэффициенте снижения массы.

Библиографический список

1. Баничук Н.В., Кобелев В.В., Рикардс Р.Б. Оптимизация элементов конструкций из композиционных материалов. М.: Машиностроение, 1988. 224 с.
2. Бакулин В.Н., Гусев Е.Л., Марков В.Г. Методы оптимального проектирования и расчета композиционных конструкций. В 2 т. Т.1. Оптимальное проектирование конструкций из композиционных и традиционных материалов. М.: Физматлит, 2008. 256 с.
3. Зиновьев П.А., Смердов А.А. Оптимальное проектирование композитных материалов. М.: Изд-во МГТУ им. Н.Э. Баумана, 2006. 103 с.

4. Нарусберг В.Л., Тетерс Г.А. Устойчивость и оптимизация оболочек из композитов. Рига, 1988. 299 с.
5. Немировский Ю.В., Янковский А.П. Рациональное проектирование армированных конструкций. Новосибирск: Наука, 2002. 488 с.
6. Смердов А.А. Основы оптимального проектирования композитных конструкций. М.: Изд-во МГТУ им. Н.Э. Баумана, 2006. – 88 с.
7. Чамис К.К. Проектирование элементов конструкций из композитов // Композиционные материалы; В 8-ми т. / Под ред. Л. Браутмана и Р. Крока. М.: Машиностроение, 1978. Т. 8, Часть 2. С. 214-254
8. Кусяков А.Ш. Проектирование композитных стрингерных пластин // Вест. Перм. ун-та: Математика. Механика. Информатика. Вып. 4(47) . Пермь, 2019. С. 44-48.

EVALUATION OF THE EFFECTIVENESS OF REINFORCING ELEMENTS IN THE PROBLEM OF OPTIMIZING A COMPOSITE PLATE

Kusyakov Alfred Sh.,

Perm State University National Research,
614990, Russia, Perm, Bukireva st., 15, kusyakov@psu.ru

The problem of optimization of a reinforced composite plate under the action of compressive loads in the plane of the plate is investigated. The target function is the mass of the structure. When constructing physical constraints, stability and strength conditions are taken into account. Most of the currently known optimization algorithms are based on the assumption that the solution to the problem exists and is unique. In this paper, we propose an algorithm for optimizing the reinforced plate, which allows us to take into account not only the multiplicity, but also the lack of a solution to the optimization problem. Numerical results are presented to evaluate the effectiveness of introducing reinforcing elements into the composite plate structure.

Key words: optimization; composite; plate; stiffeners, stability; strength.

РАЗРАБОТКА АЛГОРИТМА ИДЕНТИФИКАЦИИ ЛИЦ ЧЕЛОВЕКА НА ОСНОВЕ ПРАВИЛ ЗОЛОТОГО СЕЧЕНИЯ

Липин Юрий Николаевич, Южаков Александр Анатольевич

Пермский национальный исследовательский политехнический университет,
614990, Россия, г. Пермь, Комсомольский проспект, д. 29,
ur-lip193530@yandex.ru

Распознавание лиц – практическое приложение теории распознавания образов, в задачу которого входит автоматическая локализация лица на фотографии и, в случае необходимости, идентификация персоны по лицу. Большая часть алгоритмов распознавания использует ключевые точки лица и их удалённость друг от друга. Определение точек лица возможно при использовании специальных библиотек (например, OpenCV). Однако это сложный и длительный процесс, требующий специальных программ, пакетов, языков программирования. В статье рассмотрен метод обнаружения и расчёта ключевых точек по правилу золотого сечения – соотношение двух величин, при котором большая величина относится к меньшей так же, как сумма величин к большей. Разработана оригинальная программа, позволяющая осуществлять данный процесс.

Ключевые слова: золотое сечение, распознавание лиц.

Из существующих трех систем анализа характерных точек лица:

- Антропология черепа акад. Герасимова;
- В используемых в криминалистике;
- В сложившейся практике теории распознавания лиц человека;

будем использовать третью, имеющими нечто общее с первыми двумя. Исходными данными для идентификации по изображению лица являются его особые точки.

Определение точек лица возможно выполнить за счет специальных библиотек, например OpenCV, которые формируют 68 точек и более. Данная библиотека требует применения сложных программных продуктов. Загрузка EmbarCadero это сложный и длительный процесс, требующий специальных программ, пакетов, языков программирования. Есть другой вариант, используемый в наших разработках – это всеобщее правило, изобретенное природой, эволюцией – закон золотого сечения. Структура всего тела человека и лица соответствует требованиям этого закона. Но небольшие отличия у каждого человека имеют место быть.

Согласно рисунку 1, расстояние от подбородка до носа равно от носа до бровей и равно от бровей до кромки волос. Лицо по высоте делится

пополам по линии зрачков глаз. Расстояние от подбородка до щели рта составляет 0.62, от подбородка до носа и есть число золотого сечения.




Рисунок 1. Разметка лица по правилам золотого сечения.

Ширина крыльев носа равна ширине глаз и расстоянию между глазами. Получаем 6 горизонтальных и вертикальных линий, т.н. 36 точек и 25 прямоугольников. На этих точках можно построить любую сетку. Причем алгоритм такой, что по любой одной точке – высоте бровей строится вся структура лица. Кроме этих имеются и дополнительные зависимости согласно закону золотого сечения:

- Ширина лица на уровне глаз принимается за единицу;
- Ширина между центрами зрачков глаз 1:0.48;
- Ширина глаза 1:0.23;
- Ширина лица на уровне рта 1:0.88;
- Длина носа 1:0.37;
- Ширина носа 1:0.25;
- Ширина губ 1:0.38;
- Переносица носа 1: 0.11;
- Площадь лица к площади image 1: 0.81.

Найденные по точкам значения лица позволяют найти отклонения в процентах и у всех лиц они индивидуальны, что позволяет по этим отклонениям идентифицировать человека по фото. Эффективность использования данного правила зависит от присутствия в образе человека (фото) очков, усов, бороды, прически и зимних предметов одежды. Решение этой проблемы достигается масштабированием лица за счет использования функции Delphi CopyRect, которая позволяет входной размер изображения преобразовать в стандартный размер 200x300 пикселей.

Далее необходимо определить наличие наклонов, поворотов лица или их комбинаций. Для этого по изображению лица составляется матрица $Mas[I,j]$, где $I=1..300$, $J=1..200$. Для коррекции яркости и контрастности

используется функция SkynLine. Запускается алгоритм Фурье (БПФ) с определением гармоник по каждому прямоугольнику из 25, получившихся по сеткам точек.

Если середина расстояний зрачков глаз, губ примерно равна 100 (+,-) 3-5 пикселей, можно изображение принять за фронтальное и алгоритм уйдет в распознавание. Если середина глаз намного больше середины губ, то алгоритм сочтет за наклон головы. Если середины равны и значительно отличаются от середины лица в 100 пикселей, то положение повернуто. Запускается тот или иной алгоритм и выполняется дальнейшее распознавание с идентификацией.

Итак, запускается проект, как показано на рисунке 2. Все точки найдены согласно законам золотого сечения. Этим точкам строится сетка вертикальных и горизонтальных линий с формированием 25 прямоугольников. Левое фото представляет исходный образец лица, производится корректировка яркости и контрастности по каждому каналу из R, G, B. В среднем цветность поддерживается единицах 100..150. светлости По левому рисунку создается массив и подвергается преобразованию алгоритмом “Собеля” (Фильтрация, выделение границ в черно белой градации). Результат алгоритма “Собеля” позволяет найти границу овала лица, одного из важнейших индивидуальных характеристик лиц человека. Алгоритмы стандартных библиотек более трудоемки по времени и сложнее в программировании и в усвоении.

Алгоритм идентификации данного варианта программы основан “на использовании Быстрого преобразования “Фурье” (БПФ) по каждому из 25 прямоугольников. В каждом из 25 прямоугольников суммируются гармоники, большие 0.5 от максимального значения с дальнейшим использованием экспоненты В результате получен вектор из 25 значений, и 26 значение, как среднее. Прямоугольники 21.25 мало информативны и поэтому их значения заменяются на другие, а именно на соотношения ширины лица на уровне глаз к другим линейным параметрам лица, например к ширине лица на уровне рта, примеры даны выше. Принципиальными значениями являются только положение бровей и ширина нижней части носа, поскольку все остальные параметры лица зависят от них. Например:

- 23-Весьма важна форма овала лица, методом МНК рассчитаны коэффициенты квадратичного полинома, в качестве X взята координата по высоте уровень рта и полученное значение будет 23 значением вектора;
- 24- Рассчитано в процентах отклонение соотношения ширины уровня глаз и рта (см. выше);
- 25- Рассчитано отношение в процентах площади овала лица к площади Image (200x300) и аналогично для других значений
- Все вектора базы данных хранятся в массиве Mst2[I,J], а значение идентифицируемого субъекта в -Mst1[1,j].

Алгоритм идентификации:

- По 26 вектору производится сортировка по возрастанию $Mst2[I,J]$, $I=1..N$, N - размер базы, $J=1..25$;
- Для анализируемого объекта также рассчитан вектор $Mst1[1,J]$;
- Методом дихометрии находится всего три вектора для выбора из $Mst2$ по 26 значению;
- Берется сумма отношений векторов $Mst2$ и $Mst1$ по \max в знаменателе, делится на 25, умножается на 100, \min из трех дает ответ. Таким образом, размер базы не влияет на время идентификации. В реальном проекте база формируется один раз с сохранением значений ее в памяти машины и с открытием при работе.

На рисунке 2 приведен пример работы программы.

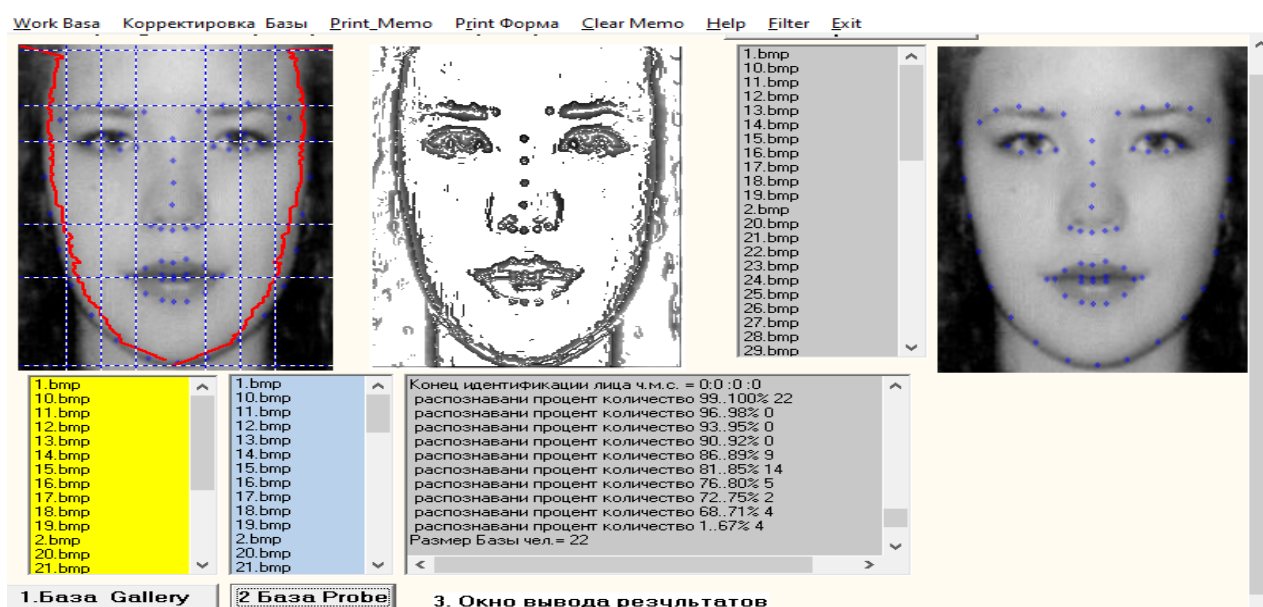


Рисунок 2. Результат работы программы

База фото состоит из 30 объектов. На идентификацию подается 60 объектов, из них 22 из базы, 8 базовых немного измененных и 30 чужих. В мемо дан результат распознавания, общий итог в 60 объектов, 22 объекта с распознаванием в 100%, остальные распределились по своим значениям. Правое фото на рисунке 2. получено после фильтрации исходного изображения с более четким качеством.

По кнопке Gallery загружается база фото лиц, и в меню 'Work База' создается база векторов $Mst2$. В окне Мемо отображается процесс создания базы с учетом времени. Далее повторяется процесс создания базы, Probe на этих же шаблонах с добавлением чужих фото. В меню work выбираем 'Проверка базы' и получаем в Мемо ответ 99-100% – 22 В Мемо отмечается, что задано и что найдено. Также выделен параметр $AVG=143$, нужный для нахождения принадлежности к этносу и полу. В данной программе используется модуль поворотов лица в пределах (+40. -40) градусов.

Библиографический список

1. Гика М. Эстетика пропорций в природе и искусстве. – М., 1936.
2. Кеплер И. О шестиугольных снежинках. – М., 1982.
3. Ковалев Ф.В. Золотое сечение в живописи. Учебное пособие. – К., 1986.
4. Мессель Э. Пропорции в античности и в средние века. – М., 1936.

DEVELOPMENT OF AN ALGORITHM FOR IDENTIFICATION OF HUMAN FACES BASED ON THE RULES OF THE GOLDEN SECTION

Lipin Yuriy N., Yuzhakov Aleksandr A.

Perm National Research Polytechnic University, Komsomolsky Av. 29, Perm,
Russian Federation, 614990, ur-lip193530@yandex.ru

Face recognition is a practical application of the theory of pattern recognition, the task of which is to automatically localize a face in a photograph and, if necessary, identify a person by face. Most of the recognition algorithms use key points of the face and their distance from each other. Determination of points of the face is possible using special libraries (for example, OpenCV). However, this is a complex and lengthy process that requires special programs, packages, programming languages. The article discusses a method for detecting and calculating key points according to the rule of the golden section – the ratio of two values, in which a large value refers to a smaller one in the same way as the sum of values to a larger one. An original program has been developed to carry out this process.

Key words: golden ratio, face recognition.

ПРОЕКТИРОВАНИЕ СИСТЕМЫ МОНИТОРИНГА СОСТОЯНИЯ ТРОСОВ ВАНТОВЫХ МОСТОВ МЕТОДОМ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ НА ОСНОВЕ ЭФФЕКТА ВИЛЛАРИ

*Манцуров Алексей Валерьевич, Назаренко Владимир Сергеевич,
Сомов Сергей Андреевич, Мерзляков Андрей Фёдорович,
Поносов Дмитрий Андреевич*

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, csomov@mail.ru

Чебыкин Иван Андреевич
ОАО «Институт Гипростроймост»,
129626, г. Москва, ул. Павла Корчагина, д. 2, chebykin@giprosm.ru

Рассматриваются теоретические основы и практическое применение эффекта Виллари на примере разработанной системы мониторинга силовых тросов вантовых подвесных мостов. Силовые тросы представляют собой ферромагнитные стержни повышенной прочности. Для ферромагнитных материалов свойствен ярко выраженный магнитоупругий эффект, позволяющий оценивать механическое состояние троса электромагнитными бесконтактными методами благодаря влиянию внешнего деформирующего воздействия на магнитные свойства троса. Демонстрируется функциональная схема измерительного блока разработанной системы мониторинга с описанием работы всех основных узлов. Разработана математическая модель, раскрывающая особенности работы измерительного блока системы мониторинга. Математическая модель сопоставляется с результатами проведенных экспериментов.

Ключевые слова: вантовые мосты, эффект Виллари, система мониторинга.

С давних пор для упрощения коммуникации человечество использует мосты. Развитие транспортной инфраструктуры, а также увеличение городов породило необходимость создания новых видов мостов, которые способны совместить в себе несколько качеств: возможность строительства на широких водоемах и на сложном рельефе местности, а также выдерживать большой транспортный поток. Вантовые мосты отвечают всем этим требованиям. Вантовый мост представляет собой тип подвесного моста, состоящий из нескольких пилонов, соединенных с дорожным полотном стальными тросами – вантами. Один такой вант состоит из отдельных тонких тросов (стрендов), а стренд, в свою очередь, формируется из шести металлических стержней, обвитых вокруг седьмого, центрального. Преимущество таких систем в том,

что каждый стелд отдельно крепится и отдельно натягивается при креплении к анкерам пилона.

Конструкция вант является, пожалуй, наиболее высокотехнологичным моментом, учитывая всю сложность его инженерного проектирования. Но в процессе конструирования возникают проблемы и вопросы о воздействии внешней среды. И разумеется, ванты, как и другие элементы моста подвержены этому воздействию, что может привести к серьезным изменениям внутри структуры, таким как обрыв жил, поэтому необходима система постоянного мониторинга для обеспечения максимальной надежности и безопасности данных структур. На данный момент для мониторинга конструкций применяются три типа датчиков: тензорезисторный, струнный и электромагнитный [1-3]. Однако они имеют некоторые недостатки, такие как непосредственное внедрение в место крепления несущей конструкции, нарушающей изоляцию стержневого элемента, а также необходимость подавать и пропускать большие токи через датчик [4-6].

Таким образом целью работы является разработка системы мониторинга для контроля механических усилий вант методом неразрушающего контроля на основе магнитоупругости, а именно эффекта Виллари.

Описание эффекта

В физике хорошо известно и достаточно широко применяется явление магнитоупругости – изменение размеров и формы тела при намагничивании. Этот эффект был обнаружен и изучен в 1842 г. Джеймсом Джоулем. По сравнению с другими веществами в ферромагнетиках явление магнитоупругости проявляется наиболее выражено. Однако существует и обратный эффект – изменение намагниченности ферромагнетика при деформации – так называемый магнитоупругий эффект или эффект Виллари [7, 8]. Изменение намагниченности при деформации объясняется тем, что при воздействии механических напряжений изменяется доменная структура ферромагнетика как показано, определяющая его намагниченность. На **Ошибка! Источник ссылки не найден.** показаны ферромагнитные образцы, помещенные в электромагнитный датчик. Черными стрелками внутри образцов показаны векторы намагниченности отдельных доменов. Прикладывая к образцу усилие растяжения F , меняются магнитные свойства системы датчик-трос, влияющие на величину переменного тока $i(t)$ возникающего в результате приложенного напряжения $U(t)$.




Рисунок 1.
Ферромагнитный образец,
помещенный в датчик

При реконфигурации доменной структуры происходит изменение магнитной проницаемости ферромагнетика, причем это изменение может быть как положительным, так и отрицательным.

Магнитоупругие свойства вещества могут быть охарактеризованы коэффициентом магнитоупругой чувствительности (1)

$$K_{\sigma} = \frac{\Delta\mu/\mu}{\sigma} \quad (1)$$

где $\Delta\mu/\mu$ - относительное изменение магнитной проницаемости, а σ - механическое напряжение.

В разработанной системе мониторинга электромагнитный датчик представляет собой соленоид с исследуемым ферромагнитным сердечником. В соответствии с законом Био-Савара-Лапласа можно определить индуктивность соленоида (2) с сердечником следующим образом

$$L = \mu_0 \mu S n^2 l \quad (2)$$

где μ_0 - магнитная постоянная, μ - магнитная проницаемость, S - площадь витка, n - число витков на единицу длины, l - длина соленоида.

При воздействии на сердечник силы натяжения F изменяется не только магнитная проницаемость μ , но и площадь поперечного сечения ферромагнетика A . Запишем изменение индуктивности соленоида (3), дифференцируя приведенное выше выражение (2)

$$\Delta L = \frac{\partial L}{\partial \mu} \Delta \mu + \frac{\partial L}{\partial S} \Delta S = L \left(\frac{\Delta \mu}{\mu} + \frac{\Delta A}{A} \right) \quad (3)$$

Проведенные эксперименты показывают, что относительным изменением площади поперечного сечения можно пренебречь, по сравнению с относительным изменением магнитной проницаемости для веществ с ярко выраженным магнитоупругим эффектом. Таким образом

$$\Delta L \approx L \frac{\Delta \mu}{\mu} = L \sigma K_{\sigma} \quad (4)$$

Исходя из полученного выражения (4) можно сделать вывод, что при определенном ферромагнитном материале для улучшения эффекта необходимо использовать соленоид с большим значением индуктивности и прикладывать значительное механическое воздействие.

Измерительный блок системы мониторинга

Рассмотрим функциональную схему разработанной системы мониторинга показанную на **Ошибка! Источник ссылки не найден.**

Через катушку L , изображенной в верхней части схемы, сердечником которой выступает стальной трос, протекает ток, формируемый системой ключей K_{ij} , драйвером (Д) и микроконтроллером (МК). Для управления системой коммутации МК использует блок ПВВ – порт ввода/вывода. Переменный ток, протекающий по соленоиду L , порождает переменное магнитное поле в объеме ферромагнитного материала. В схему введен низкоомный резистор R , на котором падает напряжение, пропорциональное току, протекающего через катушку L . При изменении магнитных свойств троса, как было показано ранее, изменяется индуктивность системы катушка-трос, что приводит к изменению величины переменного тока. Так как ток, протекающий по резистору R , обладает достаточно сложной формой, целесообразно измерять его среднее за период значение. Преобразование переменного сигнала в постоянное – среднее значение тока, выполняет фильтр нижних частот (ФНЧ). Далее сигнал оцифровывается с помощью встроенного в МК аналого-цифрового преобразователя (АЦП). Дальнейшая обработка и интерпретация оцифрованных данных осуществляется в разработанном приложении на персональном компьютере (ПК). Температура троса и катушки измеряется с помощью выносных датчиков температуры ДТ1 и ДТ2 соответственно. Место подключения катушки на схеме обозначено специальными контактными площадками и подписаны как L .

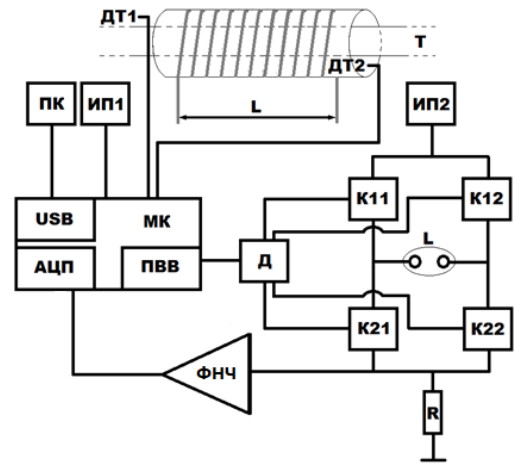


Рисунок 2. Функциональная схема измерительного блока системы мониторинга

Математическая модель измерительного блока

Для построения математической модели измерительного блока рассмотрим эквивалентную схему, показанной на Рисунок . Здесь величины R_D и L_D отвечают за соленоид датчика, а R_L , L_L , C_L – параметры кабеля, которым подключается датчик, R_i – сопротивление токоизмерительного резистора.

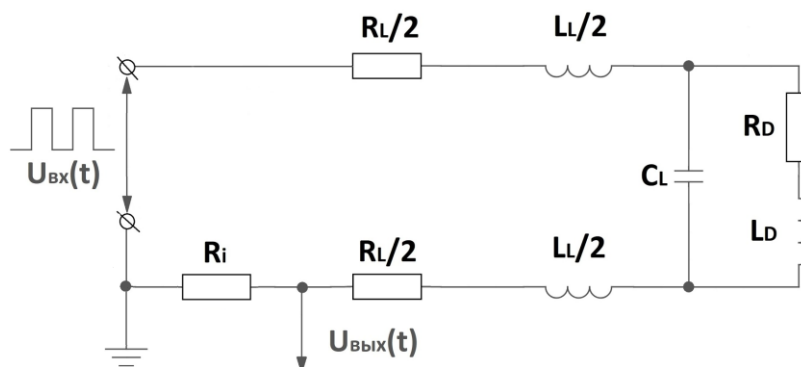


Рисунок 4. Эквивалентная схема измерительного блока

На вход системы поступает периодический прямоугольный сигнал (5), описываемый следующей функцией

$$U_{\text{ex}}(t) = U_0(\sigma(t) - \sigma(t - \tau)) \quad (5)$$

где U_0 – амплитуда входного сигнала; $\sigma(t)$ – функция включения, которая равна 1 при $t \in [0; +\infty)$; τ – время единичного импульса. В момент времени $t = 0$ $U_{\text{ex}} = U_0$, далее после $t = \tau$ $U_{\text{ex}} = 0$, до времени $t = T$, которое является периодом сигнала. $U_{\text{ex}}(t)$ можно представить как сумму падений напряжений (6) на элементах цепи:

$$U_{\text{ex}}(t) = U_{R_L}(t) + U_{L_L}(t) + U_{C_L}(t) + U_{L_L}(t) + U_{R_L}(t) + U_{R_i}(t) \quad (6)$$

Данное выражение представляет собой интегро-дифференциальное уравнение относительно токов, протекающих в приведенной схеме.

Применим к полученному выражению (6) преобразование Лапласа $L[]$ и получим передаточную функцию (7)

$$W(p) = \frac{U_{\text{вых}}(p)}{U_{\text{ex}}(p)} = \quad (7)$$

$$\frac{R_i + R_i C_L R_D p + R_i C_L L_D p^2}{R_L + R_D + R_i + p(R_L C_L R_D + L_L + R_i C_L R_D + L_D) + p^2(R_L C_L L_D + L_L C_L R_D + R_i C_L L_D) + p^3(L_L C_L L_D)}$$

Пренебрегая кубическим слагаемым в знаменателе передаточной функции (7), можно получить аналитическое выражения для выходного напряжения при заданном входном сигнале. В заданных диапазонах изменения параметров полученная аналитическая зависимость с заданной точностью совпадает с численным решением исходной передаточной функции. Таким образом модифицированная передаточная функция (8) принимает следующий вид

$$W(p) = \frac{\alpha}{l} \left[1 + \frac{p\xi + \zeta}{(p - p_{1п})(p - p_{2п})} \right] \quad (8)$$

где $p_{1п}$ и $p_{2п}$ полюсы функции $W(p)$ и введены следующие обозначения:

$$\alpha = R_i C_L L_D \quad l = R_L C_L L_D + L_L C_L R_D + R_i C_L L_D$$

$$\beta = R_i C_L R_D \quad m = R_L C_L R_D + R_i C_L R_D + L_L + L_D$$

$$\gamma = R_i \quad n = R_L + R_D + R_i$$

$$\xi = \frac{\beta}{\alpha} - \frac{m}{l} \quad \zeta = \frac{\gamma}{\alpha} - \frac{n}{l}$$

В пространстве комплексной частоты образ выходного сигнала (9) может быть определен как произведение передаточной функции $W(p)$ и

образа входного сигнала $U_{\text{ex}}(p)$

$$U_{\text{вых}}(p) = W(p)U_{\text{ex}}(p) \quad (9)$$

$$U_{\text{ex}}(p) = L[U_{\text{вых}}(t)] = L[U_0(\sigma(t) - \sigma(t - \tau))] = \frac{U_0}{p}(1 - e^{-\tau p})$$

где

Таким образом

$$U_{\text{вых}}(p) = \frac{\alpha}{l} \left[1 + \frac{p\xi + \zeta}{(p - \tilde{\omega}_1)(p - \tilde{\omega}_2)} \right] \frac{U_0}{p} (1 - e^{-\tau p}) \quad (10)$$

Применив обратное преобразование Лапласа для (11)

$$U_{\text{вых}}(p) = L^{-1}[W(p)U_{\text{ex}}(p)],$$

получим функцию выходного сигнала (12) во временном t пространстве

$$U_{\text{вых}}(t) = \frac{\alpha U_0}{l} \left[\left(1 + \frac{\zeta}{\tilde{\omega}_1 \tilde{\omega}_2} + \frac{(\tilde{\omega}_1 - \tilde{\omega}_2)^{-1} (\zeta \tilde{\omega}_1 + \xi \tilde{\omega}_2)}{\tilde{\omega}_1} e^{\tilde{\omega}_1 t} + \frac{(\tilde{\omega}_1 - \tilde{\omega}_2)^{-1} (\zeta \tilde{\omega}_2 + \xi \tilde{\omega}_1)}{\tilde{\omega}_2} e^{\tilde{\omega}_2 t} \right) - \left(1 + \frac{\zeta}{\tilde{\omega}_1 \tilde{\omega}_2} + \frac{(\tilde{\omega}_1 - \tilde{\omega}_2)^{-1} (\zeta \tilde{\omega}_1 + \xi \tilde{\omega}_2)}{\tilde{\omega}_1} e^{\tilde{\omega}_1 (t - \tau)} + \frac{(\tilde{\omega}_1 - \tilde{\omega}_2)^{-1} (\zeta \tilde{\omega}_2 + \xi \tilde{\omega}_1)}{\tilde{\omega}_2} e^{\tilde{\omega}_2 (t - \tau)} \right) \right] = \frac{\alpha U_0}{l} [U_{\text{вых}_1}(t) - U_{\text{вых}_2}(t - \tau)] \quad (12)$$

В результате изменения температуры датчика и магнитных свойств сердечника, исходный сигнал претерпевает существенные изменения. Для оценки этих изменений выполняется операция усреднения переменного выходного сигнала (13), которая может быть записана следующим образом

$$\bar{U}_{\text{вых}}(t) = \frac{\alpha U_0}{l} \left[\frac{1}{T} \int_0^T U_{\text{вых}_1}(t) dt - \frac{1}{T} \int_{\tau}^T U_{\text{вых}_2}(t - \tau) dt \right] \quad (13)$$

Конечное выражение имеет вид

$$\bar{U}_{\text{вых}}(t) = \frac{\alpha U_0}{l} \frac{1}{T} \left[\tau + \frac{\zeta \tau}{\tilde{\omega}_1 \tilde{\omega}_2} + \frac{\xi e^{\tilde{\omega}_1 \tau} (1 - e^{-\tilde{\omega}_1 \tau})}{\tilde{\omega}_1 (\tilde{\omega}_1 - \tilde{\omega}_2)} + \frac{\zeta e^{\tilde{\omega}_2 \tau} (1 - e^{-\tilde{\omega}_2 \tau})}{\tilde{\omega}_2 (\tilde{\omega}_1 - \tilde{\omega}_2)} + \frac{\xi e^{\tilde{\omega}_1 (t - \tau)} (1 - e^{-\tilde{\omega}_1 (t - \tau)})}{\tilde{\omega}_1 (\tilde{\omega}_1 - \tilde{\omega}_2)} + \frac{\zeta e^{\tilde{\omega}_2 (t - \tau)} (1 - e^{-\tilde{\omega}_2 (t - \tau)})}{\tilde{\omega}_2 (\tilde{\omega}_1 - \tilde{\omega}_2)} \right] \quad (14)$$

Для проверки справедливости построенной математической модели был проведен ряд экспериментов на универсальной испытательной машине Zwick Z-250 фирмы Zwick/Roell (Германия). Проводились испытания на растяжение троса при различных условиях нагружения (температура, скорость нагружения).

Теоретические (сплошная линия) и экспериментальные зависимости представлены на Рисунок 3. Сравнение экспериментальных и теоретических зависимостей: а) – график зависимости эквивалентного тока, измеряемого системой от температуры датчика, б) – график зависимости эквивалентного тока измеряемого системой от прикладываемого к тросу усилия

. На Рисунок 3. Сравнение экспериментальных и теоретических зависимостей: а) – график зависимости эквивалентного тока, измеряемого системой от температуры датчика, б) – график зависимости эквивалентного тока измеряемого системой от прикладываемого к тросу усилия

а изображены зависимости эквивалентного измеряемого тока от температуры датчика, а на Рисунок 3. Сравнение экспериментальных и теоретических зависимостей: а) – график зависимости эквивалентного тока, измеряемого системой от температуры датчика, б) – график зависимости эквивалентного тока измеряемого системой от прикладываемого к тросу усилия

б – зависимости эквивалентного измеряемого тока от прикладываемого к образцу усилия. Видно, что экспериментально полученные данные довольно точно совпадают с теоретическими.




Рисунок 3. Сравнение экспериментальных и теоретических зависимостей: а) – график зависимости эквивалентного тока, измеряемого системой от температуры датчика, б) – график зависимости эквивалентного тока измеряемого системой от прикладываемого к тросу усилия

Заключение

Рассмотрены теоретические основы и практическое применение эффекта Виллари на примере разработанной системы мониторинга силовых тросов вантовых подвесных мостов. Разработана математическая модель, раскрывающая особенности работы измерительного блока системы мониторинга. Показано, что математическая модель хорошо согласуется с результатами проведенных экспериментов. Построенная модель позволяет выявлять нетривиальные зависимости, что делает возможным улучшать конструкцию системы мониторинга в целом.

По результатам работы зарегистрированы патенты на изобретение [9] и полезную модель [10].

Библиографический список

1. Sumitro S., Jarosevic A., Wang M. L. Elasto-magnetic sensor utilization on steel cable stress measurement //The First fib Congress, Concrete Structures in the 21th Century, Osaka. – 2002. – С. 13-19.
2. Cappello C. et al. Calibration of elasto-magnetic sensors on in-service cable-stayed bridges for stress monitoring //Sensors. – 2018. – Т. 18. – №. 2. – С. 466.
3. Liu X. et al. Comparison of AC and pulsed magnetization-based elasto-magnetic methods for tensile force measurement in steel strand //Measurement. – 2018. – Т. 117. – С. 410-418.
4. Zhang R. et al. Temperature compensation of Elasto-Magneto-Electric (EME) sensors in cable force monitoring using BP Neural Network //Sensors. – 2018. – Т. 18. – №. 7. – С. 2176.
5. Duan Y. F. et al. Development of elasto-magneto-electric (EME) sensor for in-service cable force monitoring //International Journal of Structural Stability and Dynamics. – 2016. – Т. 16. – №. 04. – С. 1640016.
6. Kim J. et al. Development of embedded EM sensors for estimating tensile forces of PSC girder bridges //Sensors. – 2017. – Т. 17. – №. 9. – С. 1989.
7. Мащенко И. П., Мащенко А. И. Теоретические основы эффекта Виллари //Известия высших учебных заведений. Северо-Кавказский регион. Технические науки. – 2005. – №. 3.
8. Zhao X., Lord D. G. Application of the Villari effect to electric power harvesting //Journal of applied physics. – 2006. – Т. 99. – №. 8. – С. 08M703.
9. Патент РФ № 2020109357, 2020.03.02. Способ мониторинга силового воздействия на ферромагнитный стержневой элемент // Патент России № 2724993. 2020. / Поносков Д. А., Чебыкин И. А., Манцуоров А. В. [и др.].
10. Патент РФ № 2020109362, 2020.03.02. Электромагнитный датчик для измерения внутренних напряжений в стержневом ферромагнитном элементе строительной конструкции// Патент России № 199215. 2020. / Поносков Д. А., Чебыкин И. А., Манцуоров А. В. [и др.].

DESIGN OF A SYSTEM FOR MONITORING THE CONDITION OF CABLE-STAYED BRIDGES BY NON-DESTRUCTIVE TESTING BASED ON THE VILLARI EFFECT

*Mantsurov Alexey V., Nazarenko Vladimir S., Somov Sergey A.,
Merzlyakov Andrey F., Ponosov Dmitry A.*

Perm State University, 15 Bukireva str., Perm, 614990, Russia, csomov@mail.ru

Chebykin Ivan A.

JSC "Institute Giprostroymost», 2 Pavel Korchagin str., Moscow, 129626, Russia,
chebykin@giprosm.ru

The theoretical foundations and practical application of the Villari effect are considered on the example of the developed system for monitoring power cables of cable-stayed suspension bridges. Power cables constitute the ferromagnetic cores of high tensile strength. For ferromagnetic materials, a pronounced magnetoelastic effect is characteristic, which makes it possible to evaluate the mechanical state of the cable using electromagnetic non-contact methods due to the influence of external deforming action on the magnetic properties of the cable. The functional diagram of the measuring unit of the developed monitoring system with a description of the operation of all the main nodes is demonstrated. A mathematical model is developed that reveals the features of the measurement unit of the monitoring system. The mathematical model is compared with the results of the experiments.

Key words: cable-stayed bridges, the effect of Villari, a monitoring system.

УДК 617

ПРИМЕНЕНИЕ АДДИТИВНЫХ ТЕХНОЛОГИЙ ПРИ ПРОТОТИПИРОВАНИИ ПРОГРЕССИВНОГО ОБОРУДОВАНИЯ

Плотников Антон Андреевич, Духанин Алексей Владиславович

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
cot1884@gmail.com

В статье рассматриваются проблемы, решения и возможности современных аддитивных технологий при разработке и изготовлении протезов и имплантов. Отмечаются высокая потребность пациентов в недорогих и простых в изготовлении имплантов и протезов. Проводится анализ сравнения имплантов изготовленных из двух типов металлов (нержавеющая сталь и титан), изготовленных посредством аддитивных технологий, которые были оперированы двум группам кроликов

соответственно. Так же приводятся преимущества имплантов и протезов изготовленные с использованием аддитивных технологий перед стандартными методами протезирования и имплантирования. Среди которых основными являются создание индивидуальных поверхностей медицинского изделия, обеспечивающих быстрое, продуктивное и эффективное лечение пациента.

Ключевые слова: протезы, протезирование, медицина, биология, аддитивные технологии, 3D сканирование, 3D печать, селективное лазерное плавление.

В современном мире, при всей его технологической составляющей, никак нельзя обойтись без травм, заболеваний, врожденных приобретений, которые редко не обходятся без потери частей человеческого организма. Согласно статистике, примерно 12% населения планеты имеют проблемы со структурой организма. Около 50 миллионов человек в год теряют конечности, из них 390 тысяч теряют ноги и 300 тысяч руки[1].

Чтобы восполнить утраченные средства жизненной необходимости используются протезы. По данным Всемирной организации здравоохранения из всех нуждающихся, доступ к услугам протезирования имеют только 5-12% человек. Данный факт обуславливается недостаточной квалифицированной медицинской помощи, а также высокая стоимость протезирования[2].

Аддитивные технологии позволяют удешевить изготовление протеза. Так, по данным статьи автора Ian Birrell, стоимость компонентов составляет от 30 до 40 фунтов. Модели для печати могут быстро изменяться и дорабатываться под нужды пациента. В тоже время автор утверждает, что основной проблемой напечатанных протезов состоит в отсутствии определенных специалистов данной области. На Филиппинах более двух миллионов человек нуждаются в протезировании или ортопедии, но есть порядка девяносто подготовленных экспертов в данной области, которые прошли полный четырех летний курс, каждый эксперт в состоянии вылечить только 400 человек в год[3].

Для решения задачи протезирования выполняются множество исследований фундаментального и клинического обоснования применения остеоинтегрированных чрескожных имплантов. Основной проблемой исследований заключается в приживаемости и инфекционной безопасности данных имплантов. В настоящее время применяется индивидуальный подход с использованием аддитивных технологий, что позволяет учитывать все возводные особенности строения и проблемы пациента, ведущие к улучшению результатов лечения пациента.

Авторы статьи [4]«Сравнительное исследование остеоинтеграции изготовленных с использование аддитивных технологий титановых и стальных имплантов в большеберцовой кости кролика в условиях внешней фиксации» проводили исследование, посвященное приживаемости разработанных посредством аддитивных технологий импланта, изготовленных методом лазерного сплавления из нержавеющей стали (EOS

PH1) и титанового сплава (Ti6Al4V), для двух групп испытуемых соответственно. Исследование показало, что при выборе материала для персонифицированных имплантатов с применением аддитивных технологий нужно учитывать помимо прочностных характеристик, а так же степень совместимости с биологическими тканями.

Аддитивные технологии послойного изготовления преобладают над традиционными, суть которых заключается в послойном удалении материала из заготовки или отлитые в форме. Установлено, что изделия изготовленные путём селективного лазерного плавления прочнее традиционных на 2-12%.

Кроме этого аддитивные технологии обладают следующими преимуществами[5]:

1. Обеспечивают пористость поверхности, необходимую для остеосинтеза и остеоинтеграции.
2. Дают возможности создавать изделия, которые плотно прилегают к кости.
3. Позволяют формировать внутри детали сложной формы каналы.
4. Позволяют создавать резьбу любой формы и диаметра, в том числе и переменным.
5. Способствуют к созданию присоединительных поверхностей для быстросменных абатментов и создания компрессионного остеосинтеза.
6. Помогают в создании переходных поверхностей, препятствующих к возникновению разного рода инфекций.

Еще один значимый плюс применения аддитивных технологий в протезировании – возможность их визуально кастомизировать. То есть сделать так, чтобы они не просто напоминали человеческие части тела, а были максимально схожими с ними. Также возможно расширить функционал протезов, например, использовать их для хранения каких-либо повседневных принадлежностей. Современные протезы становятся даже аксессуарами.

Люди перестают их стесняться. В качестве примера хочется показать выдержку из страницы социальной сети «Instagram» русского блогера, рисунок ниже, который называется себя киборг. Он любит иронизировать над собой и пропагандирует благотворительность фондам, которые занимаются развитием протезирования.



Рисунок 1. Российский блогер

Если проанализировать историю развития протезов, то, как менялись технологий и то, к чему люди стремятся, то становится понятно, что внедрение и использование аддитивных технологий в протезировании – закономерная тенденция. Они открывают новые возможности в сфере протезирования и позволяют снизить стоимость изделий. Именно с помощью аддитивных технологий уже создаются и будут создаваться протезы будущего. Развитие аддитивных технологий в протезировании очень актуально и полезно для современного общества.

Библиографический список

1. Морозов А.М., Кадыков В.А. и др., Биопротезирование. История и современность, современные проблемы науки и образования. – 2019. – №4.
2. Standarts for Prosthetics and Orthotics. Part 1: Standarts. – World Health Organization: 2017. – с.28.
3. Birrell I., 3D-printed prosthetic limbs: the next revolution in medicine // The Guardian. – 19.02.2017.
4. Еманов Е.А., Кузнецов В.П. и др., Сравнительное исследование остеоинтеграции изготовленных с использованием аддитивных технологий титановых и стальных имплантов в большеберцовой кости кролика в условиях внешней фиксации, Травматология и ортопедия России, 2020.
5. Кузнецов В.П., Горгоц В.Г. Аникеев А.А., Еманов А.А., Производство новых внутрикостных остеоинтегрируемых имплантов методом аддитивных технологий, Вестник КГУ, 2017 № 2

APPLICATION OF ADDITIVE TECHNOLOGIES IN THE DESIGN OF PROGRESSIVE EQUIPMENT

Plotnikov Anton A., Duhanin Aleksei V.
State National Research Politechnical University of Perm,
614000, Russia, Perm, Komsomolsky Av. 29,
cot1884@gmail.com

The article discusses the problems, solutions and possibilities of modern additive technologies in the development and manufacture of prostheses and implants. There is a high patient demand for inexpensive and easy-to-manufacture implants and prostheses. An analysis is made of comparing implants made of two types of metals (stainless steel and titanium), made using additive technologies, which were operated on two groups of rabbits, respectively. The advantages of implants and prostheses made using additive technologies over standard methods of prosthetics and implantation are also given. Among them, the main ones are the creation of individual surfaces of a medical device that provide fast, productive and effective patient treatment.

Key words: prostheses, prosthetics, medicine, biology, additive technologies, 3D scanning, 3D printing, selective laser melting.

УДК 519.2

О СООТНОШЕНИЯХ, СВЯЗЫВАЮЩИХ КУМУЛЯНТЫ С ЦЕНТРАЛЬНЫМИ МОМЕНТАМИ, И ИХ ПРИМЕНЕНИЕ

Полосков Игорь Егорович

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, *polosk@psu.ru*

В первой части работы рассматривается решение задачи о построении соотношений между смешанными центральными моментами и кумулянтами (семиинвариантами) произвольной векторной случайной величины. Искомые соотношения строятся на основе формальных операций над рядами Маклорена, которые представляют собой различные разложения характеристической функции случайного вектора. В рассматриваемом случае коэффициентами разложений являются смешанные начальные моменты, кумулянты и центральные моменты. Одним из приложений полученных рекуррентных соотношений является их использование для замыкания системы обыкновенных дифференциальных уравнений (ОДУ) для функций математических ожиданий и функций центральных моментов до заданного порядка, которые являются основными вероятностными спецификациями для вектора состояния системы стохастических обыкновенных

дифференциальных уравнений (СОДУ), описывающей поведение стохастической динамической системы. Во второй части работы представлен вывод общего вида системы ОДУ для указанных моментных функций.

Ключевые слова: начальный момент, центральный момент, кумулянт, семиинвариант, квазимомент, замыкание, (стохастическое) обыкновенное дифференциальное уравнение.

Введение

Известно, что применение вероятностных методов исследования различных процессов и явлений нередко приводит к необходимости использования таких статистических характеристик случайных объектов, как моменты, кумулянты и квазимоменты различных порядков. Для практического использования указанных характеристик случайных величин необходимо знание простых зависимостей между ними. В большинстве же известных русско- и иноязычных руководств по приложениям теоретико-вероятностных методов таких важнейших соотношений нет, а если и есть, то они не очень удобны для применения (см., например, [1-3]): в таких руководствах, как правило, приводятся только небольшое число частных связей для этих характеристик низших порядков или же варианты ограниченного использования (например, в [1] можно найти соотношения между центральными моментами и кумулянтами, но для случая нулевых математических ожиданий). Поэтому в практических задачах исследователи вынуждены пользоваться громоздкими формулами, плохо приспособленными для анализа объектов с многими степенями свободы.

В первой части работы рассматривается решение задачи о построении общих рекуррентных соотношений между смешанными центральными моментами и кумулянтами (семиинвариантами) произвольной векторной случайной величины. Искомые соотношения строятся на основе формальных операций над рядами Маклорена, которые представляют собой различные разложения характеристической функции случайного вектора.

Вывод соотношений

При построение искомых связей будем опираться на схему, изложенную в работе [4] и примененную нами ранее для вывода рекуррентных соотношений между начальными моментами, кумулянтами и квазимоментами [5, 6], в предположении, что все требуемые числовые характеристики случайного вектора X существуют, а формальные действия над бесконечными рядами допустимы.

Введем следующие мультииндексные обозначения и зафиксируем их свойства:

$$\begin{aligned} \alpha &= \{\alpha_1, \alpha_2, \dots, \alpha_n\}, & \beta &= \{\beta_1, \beta_2, \dots, \beta_n\}, \\ k_1 \alpha + k_2 \beta &= \{k_1 \alpha_1 + k_2 \beta_1, k_1 \alpha_2 + k_2 \beta_2, \dots, k_1 \alpha_n + k_2 \beta_n\}, \\ e_i &= \{\delta_{ij}\}, & j &= 1, 2, \dots, n, & e_{ij} &= e_i + e_j, & (1) \\ x^\alpha &= x^{\alpha_1} \cdot x^{\alpha_2} \cdot \dots \cdot x^{\alpha_n}, & C_\alpha^\beta &= C_{\alpha_1}^{\beta_1} \cdot C_{\alpha_2}^{\beta_2} \cdot \dots \cdot C_{\alpha_n}^{\beta_n}, & C_k^\ell &= \frac{k!}{\ell!} \end{aligned}$$

$$\sum_{\beta=0}^{\alpha} h_{\beta} = \sum_{\beta_1=0}^{\alpha_1} \sum_{\beta_2=0}^{\alpha_2} \dots \sum_{\beta_n=0}^{\alpha_n} h_{\beta_1 \beta_2 \dots \beta_n}, \quad |\beta| = \beta_1 + \beta_2 + \dots + \beta_n,$$

где δ_{ij} – символ Кронекера, C_k^{ℓ} – число сочетаний.

Кроме этого, пусть $X = \{X_1, X_2, \dots, X_n\}$ – случайный вектор с плотностью распределения $p(x)$ и характеристической функцией $\Theta(u)$:

$$\Theta(u) = E[e^{X \cdot u}],$$

где $E[\dots]$ – символ математического ожидания, i – мнимая единица, $u = \{u_1, u_2, \dots, u_n\}$.

Функцию $\Theta(u)$, преобразуя или обобщая соотношения из работ [1, 7] и др., а также вводя наши дополнительные новые, можно записать так:

$$\Theta(u) = \sum_{\alpha=0}^{\infty} \frac{i^{|\alpha|}}{\alpha!} m_{\alpha} u^{\alpha}, \quad (2)$$

$$\Theta(u) = \exp \left[\sum_{\alpha=0}^{\infty} \frac{i^{|\alpha|}}{\alpha!} \kappa_{\alpha} u^{\alpha} \right], \quad (3)$$

$$\Theta(u) = \exp \left[i \cdot m \cdot u - \frac{1}{2} \sum_{j,k=1}^n D_{jk} u_j u_k \right] \cdot \sum_{\alpha=0}^{\infty} \frac{i^{|\alpha|}}{\alpha!} q_{\alpha} u^{\alpha}, \quad (4)$$

$$\Theta(u) = E[e^{X \cdot u}] = e^{m \cdot u} \cdot E[e^{(X-m) \cdot u}] = e^{m \cdot u} \cdot \sum_{\alpha=0}^{\infty} \frac{i^{|\alpha|}}{\alpha!} \mu_{\alpha} u^{\alpha}, \quad (5)$$

где m_{λ} , κ_{λ} , q_{λ} , μ_{λ} – смешанные начальные моменты, кумулянты (семиинварианты) и квазимоменты случайного вектора X ($m_0 = 1$, $\kappa_0 = 0$, $q_0 = 1$, $\mu_0 = 1$), $m = \{m_1, m_2, \dots, m_n\}$ – математические ожидания компонент вектора X , $D_{jk} = E[(X_j - m_j)(X_k - m_k)]$ – элементы матрицы дисперсий (ковариаций) Δ .

В работах [5, 6] были построены соотношения, связывающие:

– начальные моменты и кумулянты:

$$m_{\alpha+e_s} = \sum_{\beta=0}^{\alpha} C_{\alpha}^{\beta} \kappa_{\beta+e_s} m_{\alpha-\beta}, \quad (6)$$

$$\kappa_{\beta+e_s} = m_{\alpha+e_s} - \sum_{\beta=0, \beta \neq \alpha}^{\alpha} C_{\alpha}^{\beta} \kappa_{\beta+e_s} m_{\alpha-\beta}, \quad (7)$$

– начальные и центральные моменты для нормально распределенного случайного вектора:

$$m_{\alpha}^N = m_s m_{\alpha-e_s}^N + (\alpha_s - 1) D_{ss} m_{\alpha-2e_s}^N + \sum_{k=1, k \neq s}^n \alpha_k D_{sk} m_{\alpha-e_{sk}}^N, \quad |\alpha| > 0, \quad (8)$$

где $\alpha \geq 0$; s – любое целое число из промежутка от 1 до n ; m_{α}^N – начальные моменты нормального распределения.

Для получения искоемых соотношений продедем следующие выкладки. Найдем производную характеристической функции по переменной u_s (s – любое от 1 до n), используя разложение (5):

$$\begin{aligned} \frac{\partial \Theta(\mathbf{u})}{\partial u_s} &= m_s e^{m \cdot \mathbf{u}} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \mu_{\alpha} u^{\alpha} + e^{m \cdot \mathbf{u}} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \alpha_s \mu_{\alpha} u^{\alpha - e_s} = \\ &= m_s e^{m \cdot \mathbf{u}} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \mu_{\alpha} u^{\alpha} + e^{m \cdot \mathbf{u}} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \mu_{\alpha + e_s} u^{\alpha}. \end{aligned} \quad (9)$$

Теперь найдем подобную производную, но используя разложение (3):

$$\frac{\partial \Theta(\mathbf{u})}{\partial u_s} = \Theta(\mathbf{u}) \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha + e_s|}{\alpha!} \kappa_{\alpha + e_s} u^{\alpha},$$

в правой части которого $\Theta(\mathbf{u})$ заменим на основе представления (5):

$$\begin{aligned} \frac{\partial \Theta(\mathbf{u})}{\partial u_s} &= e^{m \cdot \mathbf{u}} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \mu_{\alpha} u^{\alpha} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha + e_s|}{\alpha!} \kappa_{\alpha + e_s} u^{\alpha} = \\ &= e^{m \cdot \mathbf{u}} \cdot \sum_{\alpha=0}^{\infty} \frac{|\alpha + e_s|}{\alpha!} u^{\alpha} \sum_{\beta=0}^{\alpha} C_{\alpha}^{\beta} \kappa_{\alpha + e_s} \mu_{\alpha - \beta}. \end{aligned} \quad (10)$$

Приравняем правые части равенств (9) и (10). После деления на $e^{m \cdot \mathbf{u}}$ будем иметь:

$$m_s \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \mu_{\alpha} u^{\alpha} + \sum_{\alpha=0}^{\infty} \frac{|\alpha|}{\alpha!} \mu_{\alpha + e_s} u^{\alpha} = \sum_{\alpha=0}^{\infty} \frac{|\alpha + e_s|}{\alpha!} u^{\alpha} \sum_{\beta=0}^{\alpha} C_{\alpha}^{\beta} \kappa_{\alpha + e_s} \mu_{\alpha - \beta},$$

или приравняв коэффициенты при одинаковых степенях u^{α} , получим искомое рекуррентное соотношение:

$$m_s \mu_{\alpha} + \mu_{\alpha + e_s} = \sum_{\beta=0}^{\alpha} C_{\alpha}^{\beta} \kappa_{\beta + e_s} \mu_{\alpha - \beta}. \quad (11)$$

Разрешая это соотношение относительно $\kappa_{\alpha + e_s}$, будем иметь:

$$\kappa_{\alpha + e_s} = m_s \mu_{\alpha} + \mu_{\alpha + e_s} - \sum_{\beta=0, \beta \neq \alpha}^{\alpha} C_{\alpha}^{\beta} \kappa_{\beta + e_s} \mu_{\alpha - \beta}. \quad (12)$$

Построение системы ОДУ для центральных моментов

Рассмотрим систему СОДУ в смысле Стратоновича следующего вида:

$$d\mathbf{X}(t) = \mathbf{f}(\mathbf{X}(t), t) + \mathbf{G}(\mathbf{X}(t), t) \circ \mathbf{W} \quad t > t_0, \quad \mathbf{X}(t_0) = \mathbf{X}^0, \quad (13)$$

где t – время ($t_0 < t \leq T < \infty$), $\mathbf{X}(t) \in \mathbb{R}^n$ – вектор состояния, $\mathbf{W}(t) \in \mathbb{R}^m$ – вектор независимых стандартных винеровских процессов, \mathbf{f} и \mathbf{G} – неслучайные функции своих аргументов, \mathbf{X}^0 – случайный вектор с известными статистическими характеристиками. Плотность вероятности $p(\mathbf{x}, t)$ векторного случайного процесса будет удовлетворять уравнению Фоккера – Планка – Колмогорова вида:

$$\frac{\partial p(\mathbf{x}, t)}{\partial t} = L[p(\mathbf{x}, t)] \equiv \frac{1}{2} \sum_{i, j=1}^n \frac{\partial^2 [b_{ij}(\mathbf{x}, t) p(\mathbf{x}, t)]}{\partial x_i \partial x_j} - \sum_{i=1}^n \frac{\partial [a_i(\mathbf{x}, t) p(\mathbf{x}, t)]}{\partial x_i}, \quad (14)$$

$$p(\mathbf{x}, t_0) = p^0(\mathbf{x}),$$

где $p^0(\mathbf{x}, t)$ – начальная плотность вероятности (вектора \mathbf{X}^0), а коэффициенты сноса a_i и диффузии b_{ij} вычисляются по формулам Стратоновича

$$a_i = f_i + \frac{1}{2} \sum_{j=1}^n \sum_{k=1}^m \frac{\partial g_{ik}}{\partial x_j} g_{jk}, \quad b_{ij} = \sum_{k=1}^m g_{ik} g_{jk}.$$

Известно, что ОДУ для компонент вектора математических ожиданий процесса $X(t)$ выглядят так [8]:

$$\dot{m}_i = \int_{\mathbb{R}^n} a_i(\mathbf{x}, t) p(\mathbf{x}, t) d\mathbf{x}.$$

Построим общую форму ОДУ для центральных моментных функций, используя мультииндексную форму записи. Умножая обе части уравнения (13) на $(x-m)^\alpha$, получим:

$$(x-m)^\alpha \frac{\partial p(\mathbf{x}, t)}{\partial t} = (x-m)^\alpha L [p(\mathbf{x}, t)],$$

или

$$\frac{\partial}{\partial t} [(x-m)^\alpha p(\mathbf{x}, t)] - \frac{\partial}{\partial t} [(x-m)^\alpha] p(\mathbf{x}, t) = (x-m)^\alpha L [p(\mathbf{x}, t)].$$

Отсюда

$$\frac{\partial}{\partial t} [(x-m)^\alpha p(\mathbf{x}, t)] = - \sum_{s=1}^n \alpha_s (x-m)^{\alpha-e_s} \dot{m}_s(\mathbf{x}, t) - (x-m)^\alpha L [p(\mathbf{x}, t)].$$

Интегрируя обе части последнего равенства по пространству \mathbb{R}^n , будем иметь:

$$\dot{m}_i = \sum_{s=1}^n \alpha_s \dot{m}_s(\mathbf{x}, t) + \int_{\mathbb{R}^n} (x-m)^\alpha \left[\frac{1}{2} \sum_{i,j=1}^n \frac{\partial^2 [b_{ij}(\mathbf{x}, t) p(\mathbf{x}, t)]}{\partial x_i \partial x_j} - \sum_{i=1}^n \frac{\partial [a_i(\mathbf{x}, t) p(\mathbf{x}, t)]}{\partial x_i} \right] d\mathbf{x}.$$

Окончательно система ОДУ для функций центральных моментов примет следующую общую форму:

$$\begin{aligned} \dot{m}_i &= \sum_{s=1}^n \alpha_s \dot{m}_s(\mathbf{x}, t) + \\ &+ \frac{1}{2} \sum_{i=1}^n \alpha_i (\alpha_i - 1) \int_{\mathbb{R}^n} (x-m)^{\alpha-2e_i} b_{ii}(\mathbf{x}, t) p(\mathbf{x}, t) d\mathbf{x} + \quad (15) \\ &+ \sum_{i=1}^{n-1} \sum_{j=i+1}^n \alpha_i \alpha_j \int_{\mathbb{R}^n} (x-m)^{\alpha-e_{ij}} b_{ij}(\mathbf{x}, t) p(\mathbf{x}, t) d\mathbf{x} + \\ &+ \sum_{i=1}^n \alpha_i \int_{\mathbb{R}^n} (x-m)^{\alpha-e_i} a_i(\mathbf{x}, t) p(\mathbf{x}, t) d\mathbf{x}. \end{aligned}$$

Заключение

При практическом применении полученных результатов в случае присутствия в системе СОДУ (13) полиномиальных нелинейностей уравнения (15) оказываются незамкнутыми. Добиться их замыкания можно с помощью последовательного использования соотношений (12) и (11). Если же нелинейности неполиномиальные, замыканию должна предшествовать

аппроксимация коэффициентов сноса и диффузии многочленами в окрестности вектора $m(t)$.

Библиографический список

1. Малахов А.Н. Кумулянтный анализ случайных негауссовых процессов и их преобразования. М.: Сов. радио, 1978.
2. Пугачев В.С., Сеницын И.Н. Теория стохастических систем: учеб. пособие для вузов. М.: Логос, 2004.
3. Primak S., Kontorovich V., Lyandres V. Stochastic methods and their applications to communications: Stochastic differential equations approach. Chichester: John Wiley & Sons, 2004.
4. Pourahmadi M. Tailor expansion of $\exp(\sum_{k=0}^{\infty} a_k z^k)$ and some applications // Amer. Math. Monthly. 1984. Vol. 91, № 5. P. 303–307.
5. Полосков И.Е. О связи моментов и кумулянтов многомерных распределений / Пермск. ун-т. Пермь, 1986. 5 с. (Деп. в ВИНТИ, № 8871–В86).
6. Poloskov I.E. CAS Mathematica in Random Studies // Proc. of Int. Conf. on Computer Science (ICCS 2003): Lecture Notes in Computer Science, № 2657. Berlin: Springer, 2003. Pt. I. P. 781–790.
7. Кузнецов П.И., Стратонович Р.Л., Тихонов В.И. Корреляционные функции в теории броуновского движения. Обобщение уравнения Фоккера--Планка // Журнал экспериментальной и теоретической физики. 1954. Т. 26, № 2. С. 189–207.
8. Маланин В.В., Полосков И.Е. Методы и практика анализа случайных процессов в динамических системах: учеб. пособие. Ижевск: Регулярная и хаотическая динамика, 2005.

ON RELATIONS BINDING CUMULANTS WITH CENTRAL MOMENTS AND THEIR APPLICATION

Poloskov Igor E.
Perm State University,
614990, Russia, Perm, st. Bukireva, 15, *polosk@psu.ru*

The first part of paper is devoted to solving the problem of constructing relations between mixed central moments and cumulants (semi-invariants) of an arbitrary vector random variable. We build the sought relations by formal operations over the Maclaurin series that are various expansions of the characteristic function of the random vector. In the case under consideration, the expansion coefficients are mixed moments, cumulants, and central moments. One of applications for the obtained recurrence relations is their usage for closure systems of ordinary differential equations (ODE) for the functions of mathematical expectations and the functions of central moments up to a given order that are the main probabilistic specifications for the state vector of a system of stochastic ODE describing a

behavior of a stochastic dynamical system. In the second part of the paper, we obtain a general form of the ODE system for the above indicated moment functions. **Keywords:** initial moment, central moment, cumulant, semi-invariant, quasi-moment, closure, (stochastic) ordinary differential equation.

УДК 004.5

ПРИКЛАДНОЙ АНТРОПОМОРФИЗМ В СЕРВИСНОЙ РОБОТОТЕХНИКЕ

*Елена Владимировна Середкина, Игорь Игоревич Безукладников
Михаил Сергеевич Долгих*

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
elena_seredkina@pstu.ru

Рассматривается проблема антропоморфизма в сервисной робототехнике. Предлагается альтернативный подход к пониманию концепции «прикладного антропоморфизма» для проектирования социальных роботов. Показана значимость прикладного антропоморфизма для решения актуальных проблем в области взаимодействия человека и робота (Human-Robot Interaction, HRI). Формулируется принцип асимметричной связи между поведенческим реализмом и высокоантропоморфной внешностью. Предлагается подход к нивелированию феномена «Зловещей долины». Предложенные положения иллюстрируются на примере сервисного робота Promobot V.4.

Ключевые слова: взаимодействие человека и робота, сервисная робототехника, прикладной антропоморфизм, феномен зловещей долины.

Автономные интеллектуальные агенты играют все более важную роль в нашей профессиональной и повседневной жизни. В этой связи возникает необходимость в понимании фундаментальных аспектов взаимодействия между человеком и умной машиной, что в свою очередь способствует развитию нового междисциплинарного поля исследования – взаимодействие человека и робота (Human-Robot Interaction, HRI). Благодаря передовым роботизированным технологиям сервисные роботы довольно активно используются сегодня в образовании, здравоохранении, туризме, индустрии развлечения и других секторах. В многочисленных исследованиях HRI основное внимание уделяется способности роботов частично имитировать социальное поведение человека для более эффективных социальных практик.

Интеграция сервисных роботов в сложные социальные среды – комплексная научная проблема, требующая для своего решения одновременного учета социально-гуманитарных, научно-технических и экономических аспектов. Одним из ключевых вопросов такой интеграции

является обеспечение готовности людей (потенциальных пользователей и клиентов) вступать во взаимодействие с сервисными роботами.

В ПНИПУ на базе научно-исследовательского центра «Центр оценки технологий» с 2018 года ведутся исследования в области HRI в рамках анализа процесса цифровизации производств и сервисов [1]. Необходимо подчеркнуть, что данные научные исследования осуществляются в сотрудничестве с российскими промышленными партнерами, в частности, с компанией «Промобот», специализирующейся на разработке и производстве сервисных роботов для бизнеса.

Одной из наиболее актуальных научных задач в HRI является разработка методологических принципов проектирования внешнего вида и поведения социальных роботов с учетом функциональных задач и специфики социальных практик.

В последние годы в рамках HRI в центре внимания находится проблема антропоморфизма, которая тесно связана с социальной робототехникой. Традиционно антропоморфизм рассматривается как когнитивная ошибка или незрелость, характерная для маленьких детей или «первобытных людей» [2]. В рамках настоящего исследования предлагается альтернативный подход, трактующий антропоморфизм как механизм эволюционной адаптации к «чуждому» внешнему миру. В этом смысле можно говорить о «прикладном антропоморфизме» (applied anthropomorphism) как эффективном инструменте для установления взаимодействия между человеком и роботом. Эта переоценка подкрепляется недавними открытиями в когнитивных науках. Согласно новой концепции, антропоморфизм представляет собой фундаментальное состояние человеческого разума, а не раннюю стадию его когнитивного развития [3,4].

Например, когда человек впервые сталкивается с роботом, он словно бы вступает на неизвестную территорию. Это вызывает беспокойство, чувство дискомфорта. И чтобы снять стресс, люди начинают приписывать роботам человеческие черты, чтобы психологически восстановить контроль над новой ситуацией, перевести ее в более знакомую плоскость. В этом смысле можно использовать антропоморфизм в качестве инструмента для облегчения взаимодействия между человеком и роботом.

Таким образом, проблема проектирования социальных роботов на основе принципа антропоморфизма выходит на первый план. Наша исследовательская группа ставит перед собой цель разработать теоретические принципы «прикладного антропоморфизма» и выявить условия активации антропоморфных проекций у пользователя в ходе HRI акта. В центре внимания находятся два ключевых фактора: 1) человекоподобный (антропоморфизирующий) внешний вид; 2) автономное движение или поведение. Теоретические исследования показывают, что усиление даже одного из этих факторов позволяет роботу достичь «социального порога»: люди начинают воспринимать его в качестве социального агента, то есть готовы с ним взаимодействовать. Другими словами, высоко антропоморфный робот может производить сильный

социальный эффект, даже если его поведенческий реализм низок, и, наоборот, поведенческий реализм (движение и поведение) приведет к запуску антропоморфных проекций даже в случае, если робот мало похож на человека.

Однако **связь между этими двумя факторами выглядит асимметричной**: поведенческий реализм важнее высоко антропоморфной внешности [5]. Когда социальный порог будет достигнут роботом только по линии человеческой внешности, а его движения или поведение будут неадекватными, т.е. несовместимыми с антропоморфной проекцией, может возникнуть «нелинейный» эффект с точки зрения социального взаимодействия. В робототехнике таким примером является эффект «Зловещей долины». Этот феномен был открыт в 1970 году японским инженером Масахиро Мори и получил название «Зловещей долины» из-за характерного «провала» на графике симпатии [6]. Согласно этому графику, человек и человекоподобное существо в принципе вызывают симпатию. Но нечто промежуточное – «почти человек» или «еще-не-человек» – воспринимается как что-то отвратительное и пугающее. Это внезапное психологическое/когнитивное отторжение является результатом именно несоответствия между внешностью и моторикой – диссонанс, возникающий из-за нереалистичных движений робота с гиперреальной внешностью человека.

Как показывают экспериментальные данные, несоответствие между внешним сходством (слабое) и движением/поведением (высокий уровень) функционирует в противоположном направлении, а именно, взаимодействие с таким автономным интеллектуальным агентом имеет тенденцию быть положительным. Другими словами, когда робот своими движениями проявляет автономную координацию с движением человека, это облегчает «коммуникацию» между ними. Человек в такой ситуации готов взаимодействовать с объектом даже при условии отсутствия сходства с человеческой внешностью. Эти результаты, согласующиеся с эмпирическими данными психологии [7], позволяют предположить, что реалистичное поведение доминирует над человеческим сходством в активизации антропоморфных проекций. (Именно поэтому можно говорить об асимметрии между двумя этими факторами).

Как показывают результаты проведенных нами практических исследований, даже в случае, когда внешность робота далека от гиперреальности, несоответствие поведенческой модели робота ожиданиям пользователей приводят к формированию неудовлетворенности и негативной реакции. Так, ряд пользователей в ходе HRI акта с роботом Promobot V.4 выражали разочарование от отсутствия ощущения «живого» общения, представления о котором частично основано на примерах из научно-фантастических фильмов и литературы. В ходе попыток свободного общения человеку, как правило, не удается установить такой «живой» контакт по причине отсутствия типичных для человека поведенческих шаблонов (в т.ч. невербальные реакции тела, мимики лица, глаз), отсутствия

индивидуальности в общении. Многие из указанных недостатков напрямую связаны с текущим уровнем технологий для тех или иных программных и аппаратных компонентов робота, и, соответственно, не могут быть легко устранены без существенных изменений в его конструктиве и ПО. Однако существует множество примеров успешного взаимодействия и «живого» контакта пользователей с мелкими птицами, рептилиями или даже насекомыми, в том числе их роботизированными аналогами. На взгляд авторов, основная причина такого различия кроется в значительно менее требовательной поведенческой модели для такого рода существ (меньшее количество паттернов поведения, меньшие ожидания пользователей от взаимодействия). При этом конкретные акты взаимодействия человека и такого робота могут быть достаточно сложными и приносить удовлетворение человеку.

В настоящее время разработчики человекоподобных роботов идут в основном по пути наращивания вычислительных мощностей, совершенствования аппаратной и программной составляющих робототехнических объектов. Несомненно, это поможет внести свой вклад в решение исследуемой проблемы, однако такой подход требует значительных затрат и ресурсов, в том числе временных. Альтернативным вариантом, может стать разработка новых принципов успешной коммуникации человека и робота, основанных на глубоком анализе типовых паттернов поведения, выбору и формированию наиболее выгодных сценариев и способов коммуникации, позволяющих значительно повысить отдачу от коммуникации без существенной модернизации «железа» и ПО робота. С коммерческой точки зрения, использование такого подхода позволит компаниям-производителям роботов значительно увеличить рыночную привлекательность своей продукции, а также выйти на сферы применения, требующих для успеха иных, более развитых коммуникационных сценариев.

Мы предлагаем выделить различные формы антропоморфизма (негативную и позитивную) и на этой основе разработать новые принципы проектирования сервисных роботов. Прежде всего, речь идет о синхронизации внешности и поведения робота, а именно, внешний облик робота не может обгонять его поведенческие характеристики. В противном случае избыточность антропоморфной формы при низком поведенческом функционале может стать барьером для эффективного взаимодействия между людьми и роботами. В рамках нашей концепции прикладного антропоморфизма может быть также решена проблема Зловещей долины.

Библиографический список

1. Е.В. Середкина, И.И. Безукладников, О.А. Бурова. Готово ли общество взаимодействовать с искусственным интеллектом и роботами? (Анализ результатов анкетирования в России и Японии) // Социально-гуманитарные знания, 2018. – №10. – С. 109-114.

2. Mitchell, S. D. (2005). “Anthropomorphism and cross-species modeling,” in *Thinking with Animals*, eds L. Daston and G. Mitman (New York: Columbia University Press), 100–118.
3. Złotowski, J., Proudfoot, D., Yogeewaran, K., and Bartneck, C. (2015). Anthropomorphism: opportunities and challenges in human-robot interaction. *Int. J. Soc. Robot.* 7, 347–360. doi: 10.1007/s12369-014-0267-6
4. Dumouchel, P., and Damiano, L. (2017). *Living with Robots*. Cambridge, MA: Harvard University Press.
5. Damiano L and Dumouchel P (2018) Anthropomorphism in Human–Robot Co-evolution. *Front. Psychol.* 9:468.
6. Mori, M. (1970). The uncanny valley. *Energy* 7, 33–35.
7. Urquiza-Hass, E. G., and Kortschal, K. (2015). The Mind behind Anthropomorphic Thinking. *Anim. Behav.* 109, 167–176.

APPLIED ANTHROPOMORPHISM IN SERVICE ROBOTICS

Seredkina Elena V., Bezukladnikov Igor I., Dolgikh Mihail S.
 Perm National Research Politechnical University,
 614000, Russia, Perm, Komsomolsky Av. 29,
 elena_seredkina@pstu.ru

The problem of anthropomorphism in service robotics is considered. An alternative approach to understanding the concept of “applied anthropomorphism” for designing social robots is proposed. The importance of applied anthropomorphism for solving urgent problems in the field of Human-Robot Interaction (HRI) is shown. The principle of an asymmetric connection between behavioral realism and highly anthropomorphic appearance is formulated. An approach to leveling the Uncanny Valley phenomenon is proposed. These provisions are illustrated by the example of Promobot service robots.

Key words: human-robot interaction (HRI), service robotics, applied anthropomorphism, uncanny valley phenomenon.

МОДЕЛИРОВАНИЕ СИСТЕМЫ ИЕРАРХИЧЕСКОГО РАСПОЗНАВАНИЯ ДЛЯ ПРЕДВАРИТЕЛЬНОГО РАСЧЁТА ХАРАКТЕРИСТИК ПРОЦЕССА³⁹

*Тур Александр Игоревич, Ахметзянов Кирилл Раисович,
Кокоулин Андрей Николаевич*

Пермский национальный исследовательский политехнический университет,
614990, Россия, г. Пермь, Комсомольский проспект, д. 29,
tur.aleksandr93@mail.ru

Рассматривается процесс расчёта оптимальных характеристик иерархической системы распознавания с применением моделирования процесса работы системы на основе системы массового обслуживания (СМО). Особенностью подобной системы является то, что система производит предварительную обработку изображения, выделяя области интереса на изображении (ROI), и распознаёт только их. Другими словами отбрасывает участки изображения не несущие полезной информации для процесса распознавания. Цель исследования является создание аналитической модели расчёта параметров системы иерархического распознавания объектов. Для этого были применены методы из теории систем массового обслуживания, теории телетрафика и статистический анализ. В результате был произведён расчёт оптимальных характеристик системы в условиях заданного размера изображения и времени, необходимого алгоритму на обработку одного пикселя.

Ключевые слова: иерархический подход, система распознавания.

Системы машинного зрения, занимающиеся распознаванием объектов, уже достаточно прочно вошли в нашу жизнь. Разрабатываются сотни платформ и алгоритмов, выполняющих эти функции. Каждая имеет свои плюсы и минусы, но почти все сходятся на том, что входное изображение анализируется целиком, каким бы большим оно не являлось. И это могут себе позволить стационарные мощные платформы, обладающие достаточным количеством вычислительных ресурсов для подобных операций. Однако очень часто возникает необходимость разработать такую систему распознавания, которая работала бы на портативной платформе или платформе с малой вычислительной мощностью. Как правило, при решении этой задачи просто наращивают вычислительные возможности устройств. Но есть альтернативный вариант решения – изменение метода извлечения полезной информации из изображения. Чаще всего объект на изображении

³⁹ Исследование выполнено при финансовой поддержке правительства Пермского края в рамках научного проекта № С26/174.6.

© Тур А.И., Ахметзянов К.Р., Кокоулин А.Н., 2020

занимает не всю площадь, оставляя участки, не несущие полезной информации для процесса распознавания. Если отбросить эти участки, то размер изображения сократится, что положительно скажется на времени распознавания изображения. Это называется методом иерархического поиска информации.

Отличием иерархического метода распознавания является то, что изображение, получаемое от камеры, проходит предобработку, а лишь потом выполняется распознавание:

- исходное изображение делится на фрагменты и сохраняется в специальной файловой системе;
- создаются дубликаты исходного изображения в более низком качестве (меньшее разрешение). [1]

Первый этап распознавания производится на дубликаты оригинального изображения с самым низким разрешением. Это снижает время поиска и количество ресурсов затрачиваемых на обработку изображения. На изображении отмечаются ROI (англ. «Region Of Interest» – область интереса), которые удовлетворяют критериям грубого предварительного поиска. Такой поиск отличается от обычного тем, что порог отсеивания ложных срабатываний значительно ниже. Благодаря этому на изображении будут обнаружены все объекты, которые хотя бы отдалённо напоминают объект поиска. Алгоритм, используя угловые координаты рамки ROI, производит расчёт новой области поиска. Фрагменты исходного изображения, соответствующие этой области, загружаются из памяти.

На втором этапе происходит обработка загруженных фрагментов исходного изображения в стандартном режиме распознавания (с высоким порогом отсеивания ложных срабатываний) – точный поиск. [2-5]

Как правило, для анализа изображения (стандартными подходами) требуется обойти «скользящим окном» все пиксели изображения. Время распознавания можно грубо рассчитать как произведение трёх чисел: высота изображения в пикселях, ширина изображения в пикселях, время, затрачиваемое на операцию распознавания для каждого пикселя. Иерархический метод значительно уменьшает первые два числа, что снижает общее время обработки. Однако следует помнить, что каждая итерация этапа грубого поиска требует некоторого времени, в которое входит не только «время на распознавание пикселя», но и время, затрачиваемое на файловые операции с изображением. [6, 7]. Кроме того, время распознавания не всегда линейно зависит от 3 названных выше величин. Из фундаментальных законов производительности вычислительных систем известна зависимость среднего времени обработки заявки от состояния загруженности системы в конкретный момент времени (коэффициент использования). Когда коэффициент использования достигает 100%, время обработки стремится к бесконечности из-за ограниченности вычислительных ресурсов. [8] В этой ситуации иерархический метод тоже имеет преимущество перед обычными методами, так как все вычисления производятся над меньшим числом пикселей.

Промоделировать возможность системы распознавания обрабатывать информацию можно представив её как n-канальную СМО с отказами. Отказы в данном случае будут представлять собой объекты, на которые система не успела среагировать из-за того, что вычислительные возможности были заняты распознавание другого объекта.

Для расчёта аналитической модели нам необходимо знать показатели λ и μ . Поэтому будем считать, что запросы к системе на распознавание объекта появляются с интенсивностью X штук в минуту. Интенсивность обслуживания, в случае одноканальной СМО с отказами можно рассчитать, зная объём информации и скорость её обработки. Допустим, что каждое изображение состоит из 1500 пикселей, которые необходимо обойти скользящим окном алгоритма распознавания. Скорость перемещения окна – 150 пикселей в секунду. Данные параметры описывают ситуацию, когда вычислительная платформа целиком принимает изображение от камеры и распознаёт его. Первая строчка таблицы 1 описывает систему, работающую с применением стандартных методов. В следующих строчках система, применяя иерархический метод. Допустим, что система изначально анализирует изображение, сжатое в 5 раз, т.е. площадь изображения составляет 300 пикселей. Для усреднения полученных результатов, предположим, что область ROI всегда в n раз меньше оригинального изображения. Это позволяет системе обрабатывать n изображений одновременно, распараллеливая процесс распознавания. Для полноты результатов промоделируем случаи, когда область ROI меньше исходного изображения в 2, 3 и 4 раза (таблицы 1).

Таблица 1 – Таблица расчёта интенсивности обслуживания

Площадь ROI	Площадь изображения в пикселях	Интенсивность обслуживания (1/с)
Без иерарх. м.	1500	0,1
1/2	1050 (300+750)	0,14
1/3	800 (300+500)	0,19
1/4	675 (300+375)	0,22

Стоит также отметить, что при использовании иерархического метода, вычислительные ресурсы, требуемые для распознавания объекта сокращаются. Это позволяет либо разделять заявку между процессами распознавания (каналы с взаимопомощью), либо одновременно обрабатывать несколько заявок, распараллеливания процесс распознавания. В данной модели будет учтён второй вариант. На основании вышеперечисленных условий были произведены и расчёты, а полученные результаты занесены в таблицу 2. Целевой функцией была выбрана относительная пропускная способность (Q) – средняя доля поступивших заявок, обслуживаемых системой в единицу времени (то есть отношение среднего числа заявок,

обслуживаемое системой в единицу времени к среднему числу поступающих за это время заявок). В таблице 2 данная величина для удобства представлена в виде процентов. Как и в таблице 1, первая строка в таблице 2 описывает систему, работающую с применением стандартных методов, а в следующих строчках система, применяя иерархический метод.

Таблица 2 – Результаты расчёта относительной пропускной способности системы распознавания объекта

Параметры системы	Интенсивность потока заявок λ (1/с)												
	1/60	5/60	10/60	15/60	20/60	25/60	30/60	35/60	40/60	45/60	50/60	55/60	60/60
Без иерарх. м.	85	54	37	28	23	19	16	14	13	11	10	9	9
ROI = 1/2	99	90	75	64	55	47	42	37	34	31	28	26	24
ROI = 1/3	100	99	95	89	82	75	69	64	59	54	51	47	44
ROI = 1/4	100	99	99	97	95	91	87	83	79	75	71	67	64

Результаты демонстрируют, что внедрение в систему иерархического метода при любой интенсивности потока заявок даёт прирост в производительности. Однако относительная пропускная способность равная 75,5% означает, что примерно в четверти случаев система распознавания будет испытывать перегрузку. В эти моменты времени время распознавания будет больше, чем обычно, что негативно скажется на всех остальных параметрах. Для эффективного применения иерархического метода распознавания относительная пропускная способность должна быть равна 100%. Поэтому, исходя из полученных результатов, необходимо обратить внимание на использование ROI = 1/3 и ROI = 1/4 при $\lambda = 1/60$. Такая система распознавания будет распознавать все поступающие изображения своевременно, а время распознавания можно будет описать достаточно близко линейной функцией (в случае если алгоритм распознавания перебирает «скользящим окном» все пиксели).

Иерархический метод распознавания изображения позволяет уменьшить число требуемых вычислительных ресурсов для этого процесса. Это достигается за счёт уменьшения разрешения исходного изображения, выделяя только важную информацию и отбрасывая ненужную. Разработанная модель может быть применена для предварительной оценки эффективности работы иерархической системы распознавания и расчёта характеристик, необходимых для оптимальной работы алгоритма. Однако стоит помнить, что платформе необходимо иметь запас вычислительных ресурсов для избегания перегрузки. Только в таком случае можно достаточно точно прогнозировать время выполнения операций.

Библиографический список

1. Кокоулин А. Методы распределенной обработки и хранения больших изображений (2013) IEEE EuroCon 2013, статья № 6625191, с. 1606-1610. DOI: 10.1109 / EUROCON.2013.6625191
2. Южаков А. А., Кокоулин А. Н., Тур А. И. Иерархическая архитектура сверточной нейронной сети в распределенной системе распознавания лиц // Нейрокомпьютеры: разработка, применение.- 2019. – Т. 21, № 3. – С. 28-34. – DOI 10.18127/j19998554-201903-04.
3. Supriya Suresh & Subaji Mohan. ROI-based feature learning for efficient true positive prediction using convolutional neural network for lung cancer diagnosis // Neural Computing and Applications, 2020
4. Кокоулин А.Н., Тур А.И., Южаков А.А., Князев А.И. Архитектура иерархической сверточной нейронной сети в распределенной системе распознавания лиц // Proceedings of the 2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus) : Jan. 29-30, 2019, St. Petersburg, Moscow, Russia / IEEE Russia North-West section [et. al.]. – [S. I.] : [s. n.], 2019. – URL: <https://ieeexplore.ieee.org/document/8656727>, Материалы конференции молодых ученых-исследователей в области электротехники и электроники (ElConRus), IEEE 2019: Санкт-Петербург, Москва, 29-30 января 2019 года, секция IEEE Российская Северо-Западная секции [Б. М.] : [б. и.], 2019. – URL: <https://ieeexplore.ieee.org/document/8656727>
5. Кокоулин А.Н., Южаков А.А., Тур А.И., Полыгалов С.В., Троегубов А.С., Коротаев В.Н. Проект по сбору контейнеров для напитков // IOP Conference Series: Earth and Environmental Science, 2019, Vol. 317. – Art. 012006. – URL: <https://iopscience.iop.org/article/10.1088/1755-1315/317/1/012006>, Серия конференций IOP: Земля и наука об окружающей среде, 2019, Т. 317. – Артикул. 012006. – URL: <https://iopscience.iop.org/article/10.1088/1755-1315/317/1/012006>
6. Clay D. Spence, John C. Pearson, and Jim Bergen. Coarse-to-Fine Image Search Using Neural Networks [режим доступа: <https://papers.nips.cc/paper/982-coarse-to-fine-image-search-using-neural-networks.pdf>]
7. Южаков А.А., Тур А.И. Выбор алгоритмов для реализации системы машинного зрения // Материалы XIV Всероссийской школы-конференции молодых ученых – 2017. – С. 377-384.
8. Крылов В.В., Самохвалова С.С. Теория телетрафика и её приложения. – СПб.: БХВ-Петербург, 2005. – 288 с.

MODELING HIERARCHICAL RECOGNITION SYSTEM FOR PRELIMINARY CALCULATION OF PROCESS CHARACTERISTICS

Tur Alexander I., Akhmetzyanov Kirill R., Kokoulin Andrey N.

Perm National Research Polytechnic University, Komsomolsky Av. 29, Perm,
Russian Federation, 614990, tur.aleksandr93@mail.ru

The process of calculating the optimal characteristics of the hierarchical recognition system is considered using modeling of the system operation process based on the mass service system (SMO). A feature of such a system is that the system preprocesses the image, highlighting areas of interest on the image (ROI), and recognizes only them. In other words, discards portions of the image that do not carry useful information for the recognition process. The purpose of the study is to create an analytical model for calculating the parameters of a hierarchical object recognition system. For this, methods from the theory of mass service systems, the theory of teletraffics and statistical analysis were applied. As a result, the optimal characteristics of the system were calculated under conditions of a given image size and the time required for the algorithm to process one pixel.

Key words: hierarchical approach, recognition system.

УДК 681.5.01

АДАПТИВНОЕ ДВУХСТОРОННЕЕ МУЛЬТИАГЕНТНОЕ УПРАВЛЕНИЕ ГАЗОТУРБИННОГО ДВИГАТЕЛЯ

*Хижняков Юрий Николаевич, Южаков Александр Анатольевич,
Сторожев Сергей Александрович, Никулин Вячеслав Сергеевич.*

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29, serpa5@mail.ru

Инструментарий технологий мягких вычислений основан на нечетких системах, вероятностных моделях, нейронных сетях, генетических алгоритмах и т.д., которые имеют свои достоинства и недостатки. Применение данного инструментария рассмотрено к авиационному газотурбинному двигателю (ГТД) летательных аппаратов, работа которых происходит в условиях неопределенности. Цель исследования: разработка адаптивного двухстороннего мультиагентного управления газотурбинного двигателя, где приняты для управления следующие контуры: частота вращения ротора свободной турбины (вентилятора), частота вращения ротора турбокомпрессора и температура газа за камерой сгорания. Методы: преобразование четких входных переменных выполнено с помощью сигмоидных функций принадлежности расположенных на интервале $-1 - +1$, где синглетон синхронно управляется разностью четких входных

переменных, а дефаззификация выполнена по методу средне взвешанного. Результаты: на базе разработанного адаптивного нечеткого регулятора состояний показано проектирование адаптивных нечетких регуляторов в каждом контуре и группового нечеткого регулятора. Практическая значимость: результаты исследований подтвердили снижение влияния неопределенности, повышение надежности управления и повышения срока эксплуатации ГТД. Расход топлива дозатора обеспечивает нахождение частоты вращения вентилятора, частоты вращения турбокомпрессора и температуры газа за камерой сгорания в заданных пределах.

Ключевые слова: нечеткий регулятор, сигмоидальная функция, фаззификатор, блок адаптации, степень активации, степень принадлежности.

Проектирование адаптивного нечеткого регулятора i - контура ГТД

Данную задачу можно решить применением нечеткого управления на базе адаптивного нечеткого регулятора [5]. Рассмотрим основные этапы проектирования адаптивного нечеткого регулятора на примере i – контура двигателя. Адаптивный нечеткий регулятор содержит адаптивный фаззификатор и дефаззификатор. Адаптивный фаззификатор преобразует четкое значение в нечеткое значение с помощью функций принадлежности, которые могут быть линейные, нелинейные: функции Гаусса и логистические функции. В дальнейшем в качестве функций принадлежности выбираются асимметричные сигмоидные функции с последующей адаптацией с помощью метода последовательного обучения. Во всех контурах ГТД лингвистическая переменная есть отклонение текущего значения переменной от заданного значения. В качестве функций принадлежности приняты сигмоидные (логистическая) функции, аналитическое описание (1) и графический вид которых (см. рис.1).

$$\begin{aligned}
 L_i(x_i) &= \left[1 + \exp(-b_i(x_i - C_i)) \right]^{-1}; \\
 H_i(x_i) &= \left[1 + \exp(-b_i(x_i - C_i)) \right]^{-1}; \\
 H_i(x_i) + L_i(x_i) &= 1;
 \end{aligned}
 \tag{1}$$

где $L_i(x)$ и $H_i(x)$ – сигмоидные функции принадлежности; b_i – коэффициент наклона функций принадлежности задаваемых в интервале $[0..1]$; C_i – заданное значение лингвистических переменных; x_i – отклонение текущего параметра от заданного значения (синглтон).




Рисунок 1. Сигмоидные функции принадлежности адаптивного нечеткого регулятора

где μ_1 и μ_2 – текущее значение степени принадлежности.

На рис. 2 приведена структура адаптивного нечеткого регулятора [7, 8, 9].

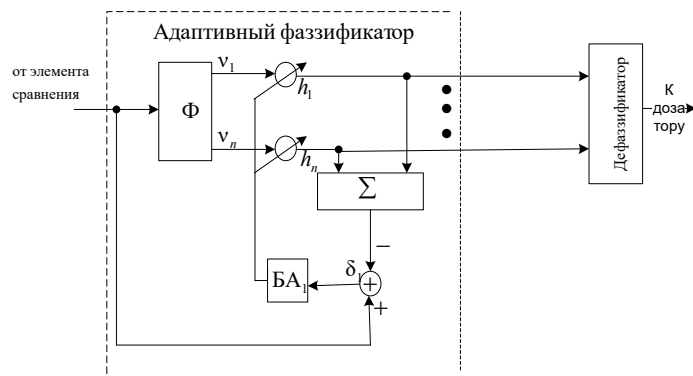


Рисунок 3. Структурная схема адаптивного нечеткого регулятора текущего параметра

где Φ_i – фаззификатор, $БА_i$ – i -блок адаптации, v_1, \dots – степени активации выхода i -фаззификатора; h_1, \dots – корректирующие коэффициенты, σ – разница модельного и текущего значений, Σ – сумма степеней принадлежности терм L и H.

При фаззификации текущего отклонения параметра с помощью синглтона определяются степени принадлежности, сумма которых всегда равна единице. Любые возмущения в контурах не отражаются в текущих значениях степеней принадлежности, которые всегда равны единице. Для учета влияния возмущений дополнительно вводятся коэффициенты для коррекции текущих значений степени принадлежности на выходе фаззификатора с помощью блока адаптации, алгоритм работы которого выполняется по рекуррентной формуле (2).

$$h_{j+1} = h_j + B(x_j - x_{jm}) \frac{V_j}{V_j^T V_j}, \text{ при } 0 < B < 1. \quad (2)$$

Формирование скобки в формуле выполняется сумматором (см. рис.2), выход которого сравнивается с текущим значением синглтона. Скорость работы алгоритма адаптации определяется значением коэффициента B, задаваемого в интервале от 0 до 1.

Проектирование дефаззификатора i –го контура управления ГТД

Дефаззификатор преобразует нечеткое значение в четкое значение с помощью функций принадлежности, которые могут быть линейные, нелинейные: функции Гаусса, логистические функции и др.

Рассмотрим дефаззификацию на базе двух унимодальных функций принадлежности и двух алгебраических уравнений Сугено [6].

Для преобразования нечеткой информации в четкую информацию вводятся два уравнения Сугено (3), которые показаны на рис.3.

$$\begin{aligned} y_1 &= 3(\omega_1^* - \omega_2^*); \\ y_2 &= (\omega_1^* - \omega_2^*); \end{aligned} \quad (3)$$

Согласно рис. 3 с помощью формулы среднее взвешенное рассчитываем выход адаптивного нечеткого регулятора по формуле (4).

$$y = \frac{y_1 \cdot \omega_1^* + y_2 \cdot \omega_2^*}{\omega_1^* + \omega_2^*} = \frac{3 \cdot (0,65 - 0,25) \cdot 1,2 + (0,65 - 0,25) \cdot 0,4}{0,25 + 0,65} = 1,18 \quad (4)$$

где ω_1^* и ω_2^* – выход адаптивного фаззификатора; y – выход адаптивного нечеткого регулятора.




Рисунок 3. Графическое представление расчетной формулы дефаззификатора

Проектирование группового нечеткого регулятора

Для каждой лингвистической переменной расхода топлива G выбрано «колоколообразные» функции принадлежности [6]. «Колоколообразная» функция принадлежности или **dsigmf**, определяется как разность двух сигмоидных функций.

Аналитическое выражение **dsigmf** имеет вид (5):

$$f_1(x, a_1, c_1) - f_2(x, a_2, c_2) = \frac{1}{1 + e^{-a_1(x - c_1)}} - \frac{1}{1 + e^{-a_2(x - c_2)}} \quad (5)$$

где x – текущее значение на входе регулятора, a_i, c_i – коэффициенты настройки разности двух сигмоид.

Графики сигмоидных функций принадлежности, формирующие **dsigmf** представлены на рис. 4.




Рисунок 4 Графическое представление расчетной формулы дефазификатора

Аналитическое описание «колоколообразных» функции принадлежности фаззификатора имеет вид (6):

$$\begin{aligned} \mu_1 &= \frac{1}{1 + \exp[-a_{11}(x_1 - C_1)]} - \frac{1}{1 + \exp[-a_{12}(x_1 - C_2)]}; \\ \mu_2 &= \frac{1}{1 + \exp[-a_{21}(x_2 - C_1)]} - \frac{1}{1 + \exp[-a_{22}(x_2 - C_2)]}; \\ \mu_n &= \frac{1}{1 + \exp[-a_{n1}(x_n - C_1)]} - \frac{1}{1 + \exp[-a_{nn}(x_n - C_2)]}. \end{aligned} \quad (6)$$

Проектирование нечеткого импликатора группового регулятора для управления диффузионными коллекторами

Учитывая нечеткую связь между лингвистическими переменными фаззификатора вводится преобразование над степенями принадлежности согласно выражению (7) и реализуется одним слоем

$$\hat{\mu} = \hat{\mu}_1 \wedge \hat{\mu}_2 \wedge \dots \wedge \hat{\mu}_n. \quad (7)$$

или согласно выражению (8)

$$\hat{\mu} = \min(\mu(x_1), \mu(x_2), \dots, \mu(x_n)) \quad (8)$$

Для управления диффузионного коллектора с настройкой на максимум реализован также один слой согласно выражению (9)

$$\bar{\mu} = \bar{\mu}_1 \cap \bar{\mu}_2 \cap \dots \cap \bar{\mu}_n. \quad (9)$$

или согласно выражению (10)

$$\bar{\mu} = \max(\mu(x_1), \mu(x_2), \dots, \mu(x_n)) \quad (10)$$

Проектирование дефаззификатора группового нечеткого регулятора

Нечеткая импликация реализуется двумя слоями нечетких нейронов, выход которых подается на дефаззификатор, описываемый в виде систем логических уравнений, записанных для n контуров управления диффузионного коллектора на увеличение подачи топлива в камеру сгорания (11):

$$\begin{aligned} \text{Если } \hat{\mu} < \Delta_0, \text{ то } G_0; \\ \text{Если } \bar{\mu} > \Delta_0, \text{ то } G_0; \\ \text{Если } \hat{\mu} > \Delta_0, \text{ то } G_0 - \Delta_0; \\ \text{Если } \bar{\mu} > -\Delta_0, \text{ то } G_0 + \Delta G. \end{aligned} \quad (11)$$

где G_0 – норма расхода топлива задается режимом, Δ_0 – добавка топлива.

На рис. 5 приведена структурная схема мультиагентного управления контурами, содержащая адаптивные нечеткие регуляторы и нечеткий групповой регулятор [9]:

Разности текущих значений параметров с программными значениями поступают на нечеткие регуляторы в i -ых контурах. Далее, выходы нечетких адаптивных регуляторов подаются на групповой регулятор. После этого, полученное значение поступает на диффузионные дозаторы с настройками на минимум и максимум.

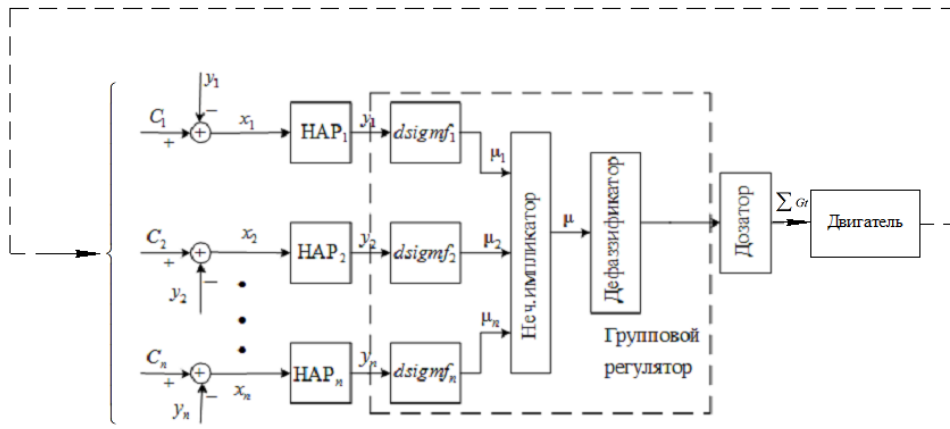


Рисунок 5. Структурная схема адаптивного двухстороннего мультиагентного управления контурами ГТД

где: C_i – уставки по текущим параметрам, $НАР_i$ – адаптивный нечеткий регулятор, x_i – отклонение заданного и текущих значений параметров ГТД, $dsigmf_i$ – «колоколообразные» функции принадлежности, y_i – выходы адаптивных нечетких регуляторов, μ_i – вход дефазсификатора, G_i – расход топлива по контурам.

Необходимо моделирование структуры, показанной на рис. 5

Библиографический список

1. Синяков А.Н., Шаймарданов Ф. А. Системы автоматического управления ЛА и их силовыми установками / М.: Машиностроение, 1991 г.
2. Рудковский В.Ю. Адаптивные системы управления газотурбинными двигателями летательных аппаратов М: МАИ, 1994, – 224 с.
3. Шульгин В.А., Гайсинский С.Я. Двухконтурные турбореактивные двигатели маломощных самолетов – М.: Машиностроение, 1984. – 168 с.
4. Гуревич О.С. Управление авиационными газотурбинными двигателями. Учебное пособие – М: Изд-во МАИ, 2001. – 100 с.
5. Клячкин А.Л. Теория воздушно-реактивных двигателей. М. Изд-во «Машиностроение», 1969.
6. Хижняков Ю.Н. Нечеткое, нейронное и гибридное управление: учеб. пособие / Ю.Н. Хижняков. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. – 303 с.
7. Пегат А. Нечеткое моделирование и управление (пер. с англ.) 2-е изд. М.: Бином. Лаборатория знаний. 2013. – 798 с. (электронная версия).
8. Хижняков Ю.Н. Алгоритмы нечеткого, нейронного и нейро-нечеткого управления в системах реального времени: учеб. пособие. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. – 156 с.

ADAPTIVE DUPLEX MULTIAGENT CONTROL OF GAS TURBINE ENGINE

*Khizhnyakov Yuri Nikolaevich, Yuzhakov Alexander Anatolyevich,
Storozhev Sergey Alexandrovich, Nikulin Vyacheslav Sergeevich.*

State National Research Politechnical University of Perm, Komsomolsky Av. 29,
Perm, 614000, Russia, cepra5@mail.ru

Toolkit of soft computing technologies is based on fuzzy systems, probabilistic models, neural networks, genetic algorithms, etc., which have their own advantages and disadvantages. The application of this toolkit is considered for the aircraft gas turbine engine (GTE) of aircraft operating under conditions of uncertainty. The purpose of the research: development of an adaptive two-way multi-agent control of a gas turbine engine, where the following circuits are adopted for control: the rotor speed of the free turbine (fan), the rotational speed of the turbocharger rotor, and the gas temperature behind the combustion chamber. Methods: transformation of clear input variables was performed using sigmoid membership functions located on the interval $-1 - +1$, where the singleton is synchronously controlled by the difference of clear input variables, and defuzzification is performed using the weighted average method Results: based on the developed adaptive fuzzy state controller, the design of adaptive fuzzy regulators in each loop and group fuzzy regulator. Practical significance: the research results confirmed the reduction of the influence of uncertainty, the increase in the reliability of control and the increase in the service life of the gas turbine engine. The dispenser fuel consumption ensures that the fan speed, the turbocharger speed and the gas temperature behind the combustion chamber are within the specified limits.

Key words: fuzzy regulator, sigmoidal function, fuzzifier, adaptation block, degree of activation, membership function.

УДК 681.5.01

НЕЧЕТКИЙ РЕГУЛЯТОР СОСТОЯНИЙ

*Хижняков Юрий Николаевич, Южаков Александр Анатольевич,
Сторожев Сергей Александрович, Никулин Вячеслав Сергеевич*

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29, cepra5@mail.ru

Инструментарий технологий мягких вычислений основан на нечетких системах, вероятностных моделях, нейронных сетях, генетических алгоритмах и т.д., которые имеют свои достоинства и недостатки. Применение данного инструментария рассмотрено к авиационному

газотурбинному двигателю (ГТД) летательных аппаратов, работа которых происходит в условиях неопределенности: Цель исследования: разработка адаптивного нечеткого регулятора состояния управления контурами ГТД без селектора, где приняты для управления следующие контуры: частота вращения ротора свободной турбины (вентилятора), частота вращения ротора турбокомпрессора. Методы: преобразование четких входных переменных выполнено с помощью сигмоидных функций принадлежности расположенных на интервале $-1 - +1$, где синглетон синхронно управляется разностью четких входных переменных, а дефазификация выполнена по методу средне взвешанного. Результаты: на базе разработанного адаптивного нечеткого регулятора состояний показано исключение штатного селектора автономного управления контурами и одновременное управление контурами ГТД. При этом исключены забросы параметров при переходе с одного контура регулирования на другой и отсутствие запаздывания в переходных процессах обусловленные изменением динамических характеристиках ГТД в процессе эксплуатации. Практическая значимость: результаты исследований подтвердили снижение влияния неопределенности, повышение надежности управления из-за отсутствия селектора и повышения срока эксплуатации ГТД. Расход топлива дозатора обеспечивает нахождение частоты вращения вентилятора и частоты вращения турбокомпрессора в заданных пределах.

Ключевые слова: нечеткий регулятор, сигмоидальная функция, фаззификатор, блок адаптации, степень активации, степень принадлежности.

Введение

Возможность получения требуемых характеристик авиационного газотурбинного двигателя (ГТД) (высотных, скоростных, дроссельных), а также необходимых динамических свойств зависит от способов управления рабочими процессами в нем с помощью систем автоматического управления (САУ) [1-5]. САУ решает вопросы устойчивости, точности регулирования на установившихся и переходных режимах, возможности аппаратной реализации программ и алгоритмов управления. На примере двухконтурного газотурбинного двигателя (ТРДД) рассмотрим проектирование нечеткого регулятора состояний с применением мультиагентного подхода. ТРДД имеет один регулирующий орган (дозатор) и несколько выходов (параметров, характеризующих рабочий процесс ТРДД). Возможные варианты управления ТРДД:

- совместная работа регуляторов контуров, воздействующих одновременно на один регулирующий орган. Данный вариант уменьшает запасы устойчивости, снижает допустимые значения коэффициентов усиления в каналах управления, что приводит к ухудшению динамической точности регулирования;

- с применением селектора, позволяющего исключить совместную работу каналов управления. Селектор обеспечивает во всех условиях работы системы воздействие на регулирующий орган (дозатор) только одного регулятора, включаемого в работу в зависимости от режима работы

двигателя. Каждый канал управления работает автономно. Согласно принципу селективного регулирования, регулируется параметр двигателя, наиболее близкий к величине, определяемой уставкой регулятора или ограничителя (программой регулирования). Например, при управлении ГТД путем изменения расхода топлива в камере сгорания на максимальных режимах работы двигателя, для того чтобы все регулируемые параметры не превысили максимальных допустимых значений (ограничение сверху), селектор должен дать команду на управление дозирующим устройством (сигнал управления), соответствующий получению минимальной величины расхода топлива. С помощью селективного регулирования по минимуму определяется очередность выполнения программ при приемистости. Если же ограничивают минимальные значения параметров (ограничения снизу), то предпочтение отдается регулятору параметров, для поддержания которого требуется наибольший расход топлива, т.е. селективное регулирование по максимуму (селектор «max»). Такой принцип применяется для согласования с регулятором сброса частоты вращения, ограничения минимального расхода топлива. Применяя последовательное селективное регулирование по минимуму и максимуму, можно обеспечить необходимое ограничение величины регулируемых параметров сверху и снизу.

Применение селектора, устраняющего зону совместной работы регуляторов, позволяет сохранить статическую точность и запасы устойчивости регулирования;

- с заменой селектора на регулятор состояния, где регулятор состояния управляет параметрами в группе.

Рассмотрим проектирование нечеткого регулятора состояний на примере управления двумя контурами: контур частоты вращения вентилятора и контур частоты вращения ротора высокого давления [6-10].

На рис. 1 приведена структура регулятора состояния.

Все контуры регулятора состояния пронумерованы следующим образом:

1 – рассогласование в контуре «n_v» (контур частоты вращения вентилятора);

2 – рассогласование в контуре «n_{вд}» (контур частоты вращения ротора высокого давления);

17 – контур «n_{v_max}» (контур максимальной частоты вращения вентилятора);

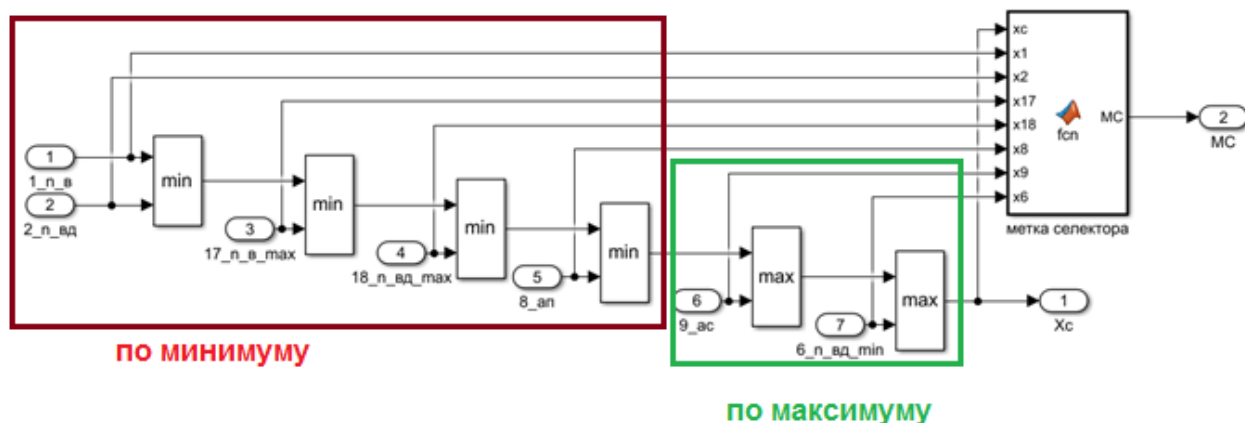


Рисунок 1. Структурная схема регулятора состояния

18 – контур «n_vd_max» (контур максимальной частоты вращения ротора высокого давления);

8 – контур «an» (контур приемистости ускорения частоты вращения ротора высокого давления);

9 – контур «ac» (контур сброса ускорения частоты вращения ротора высокого давления);

6 – контур «n_vd_min» (контур минимальной частоты вращения ротора высокого давления).

Выделим на структурной схеме (см. рис.1) часть регулятора состояния, работающего на уменьшение подачи топлива дозатором в камеру сгорания, с названием «селектор max» и часть регулятора состояния, работающего на увеличение подачи топлива дозатором, с названием «селектор min».

На рис.2 приведена структура нечеткого регулятора состояния, где «селектор min» и «селектор max» реализованы нечеткой логикой.

Зададимся функциями принадлежности нечеткого регулятора состояния:

- функция принадлежности 1 есть разность рассогласований в контурах «n_v» и «n_vd» для реализации шага 1;

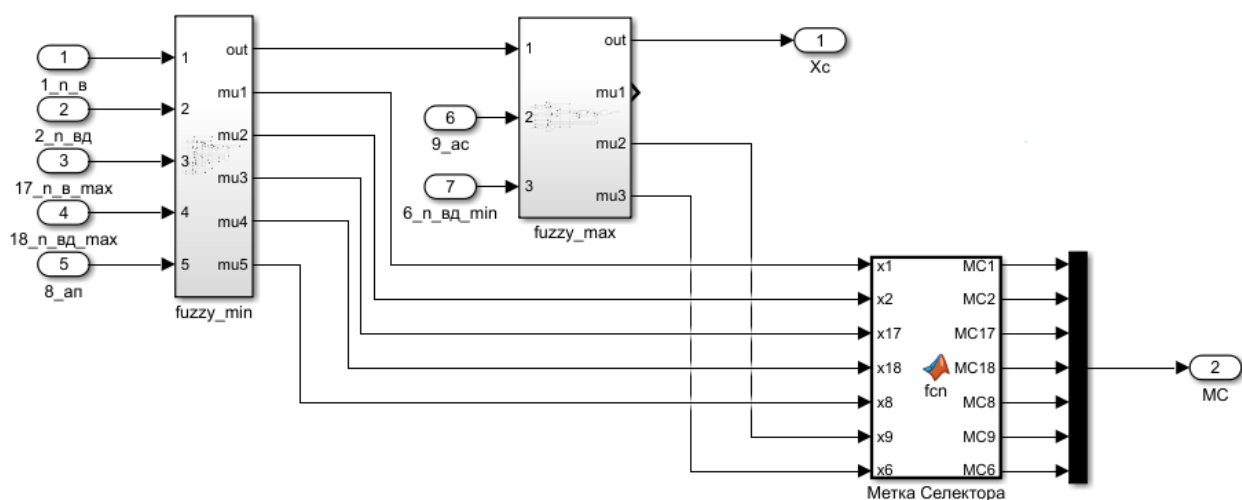


Рисунок 2 Структура нечеткого регулятора состояния

- функция принадлежности 2 есть разность контура «n_v_max» и шага 1;
- функция принадлежности 3 есть разность контура «n_vd_max» и шага 2;
- функция принадлежности 4 есть разность контура «ap» и шага 3;
- функция принадлежности 5 есть разность контура «ac» и шага 4;
- функция принадлежности 6 есть разность контура «n_vd_min» и шага 5.

Шаг 6 – выход нечеткого регулятора состояния. Все изменения входов нечеткого регулятора состояния сопровождаются метками МС для контроля последнего.

Фаззификация нечеткого «селектора min» выполняется с помощью асимметричных сигмоидных функций на интервале -1 – +1 согласно выражению (1)

$$H_1(x_1) = [1 + \exp(-b_1(x_1 - C_1))]^{-1} \text{ (много)}. \quad (1)$$

Асимметричные сигмоидные функции должны отличаться друг от друга разными коэффициентами крутизны b .

Фаззификация нечеткого «селектора max» выполняется с помощью асимметричных сигмоидных функций на интервале -1 – +1 согласно выражению (2).

$$L_2(x_2) = [1 + \exp(b_2(x_2 - C_2))]^{-1} \text{ (мало)}. \quad (2)$$

Формирование степеней принадлежности в обоих нечетких селекторах выполнено на синглетонной основе.

Дефаззификация нечеткого «селектора min» выполняется по методу средне взвешанного помощью формулы согласно выражению (3).

$$out = \frac{\sum_{i=1}^n \mu_i \cdot x_i}{\sum_{i=1}^n \mu_i}, \sum_{i=1}^n \mu_i > 0; \quad (3)$$

$$out = \min(x_1, x_2, \dots, x_i), \sum_{i=1}^n \mu_i = 0.$$

Дефаззификация нечеткого «селектора max» выполняется также по методу средне взвешанного помощью формулы согласно выражению (4)

$$out = \frac{\sum_{i=1}^n \mu_i \cdot x_i}{\sum_{i=1}^n \mu_i}, \sum_{i=1}^n \mu_i > 0; \quad (4)$$

$$out = \max(x_1, x_2, \dots, x_i), \sum_{i=1}^n \mu_i = 0.$$

Заключение

1. Разработан нечеткий регулятор состояний на базе структурной схемы штатного селектора.

2. Замена в штатном селекторе релейной логики на нечеткое управление исключает неоднозначность управления контуров газотурбинного двигателя.

Библиографический список

1. Синяков А.Н., Шаймарданов Ф. А. Системы автоматического управления ЛА и их силовыми установками / М.: Машиностроение, 1991 г.
2. Адаптивные системы управления газотурбинными двигателями летательных аппаратов / В.Ю.Рудковский [и др.] М: МАИ,1994, – 224 с.
3. Шульгин В.А., Гайсинский С.Я. Двухконтурные турбореактивные двигатели маломощных самолетов – М.: Машиностроение, 1984. – 168 с.
4. Гуревич О.С. Управление авиационными газотурбинными двигателями. Учебное пособие – М: Изд-во МАИ, 2001. – 100 с.
5. Клячкин А.Л. Теория воздушно-реактивных двигателей. М. Изд-во «Машиностроение», 1969.
6. Хижняков Ю.Н. Нечеткое, нейронное и гибридное управление: учеб. пособие / Ю.Н. Хижняков. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. – 303 с.
7. Пегат А. Нечеткое моделирование и управление (пер. с англ.) 2-е изд. М.: Бинوم. Лаборатория знаний. 2013. – 798 с. (электронная версия).
8. Хижняков Ю.Н., Южаков А.А. Нейро-нечеткий регулятор частоты газотурбинного двигателя. Приборы. – 2010. – № 5. – С. 17–21.
9. Хижняков Ю.Н. Алгоритмы нечеткого, нейронного и нейро-нечеткого управления в системах реального времени: учеб. пособие. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. – 156 с.
10. Хижняков Ю.Н. Современные проблемы теории управления/ Ю.Н. Хижняков. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2015 г. – 237 с.

FUZZY STATE REGULATOR

*Khizhnyakov Yuri Nikolaevich, Yuzhakov Alexander Anatolyevich,
Storozhev Sergey Alexandrovich, Nikulin Vyacheslav Sergeevich.*

State National Research Politechnical University of Perm, Komsomolsky Av. 29,
Perm, 614000, Russia, cepra5@mail.ru

Toolkit of soft computing technologies is based on fuzzy systems, probabilistic models, neural networks, genetic algorithms, etc., which have their own advantages and disadvantages. The application of this toolkit is considered for an aircraft gas turbine engine (GTE) of aircraft, the operation of which occurs under conditions of uncertainty: Purpose of the study: development of an adaptive fuzzy controller of the control state of GTE circuits without a selector, where the following loops are taken for control: rotor speed of a free turbine (fan) , the rotational speed of the rotor of the turbocharger. Methods: transformation of clear input variables was performed using sigmoid membership functions located on the interval $-1 - +1$, where the singleton is synchronously controlled by the difference of clear input variables, and defuzzification is performed using the weighted average method Results: based on the developed adaptive fuzzy state controller,

the standard selector is excluded autonomous control of loops and simultaneous control of GTE loops. At the same time, overshoots of parameters during the transition from one control loop to another and the absence of delay in transient processes due to changes in the dynamic characteristics of the gas turbine engine during operation are excluded. Practical relevance: the research results have confirmed a decrease in the influence of uncertainty, an increase in control reliability due to the absence of a selector and an increase in the service life of a gas turbine engine. The fuel consumption of the metering unit ensures that the fan speed and the turbocharger speed are within the specified limits.

Key words: fuzzy regulator, sigmoidal function, fuzzifier, adaptation block, degree of activation, membership function.

УДК 004.89

ПРОГНОЗИРОВАНИЕ СТОИМОСТИ АВТОМОБИЛЯ НА ОСНОВЕ ЕГО ХАРАКТЕРИСТИК

Медведев Вячеслав Сергеевич

Национальный исследовательский университет «Высшая школа экономики»,
Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38,
steinswriter@gmail.com

На базе нейронной сети была разработана математическая модель, прогнозирующая стоимость автомобиля на основе его характеристик. С помощью анализа математической модели были выявлены наиболее значимые характеристики, влияющие на стоимость автомобиля.

Ключевые слова: автомобиль, стоимость, прогнозирование, математическая модель, нейронная сеть.

В наше время количество продаж и покупок автомобилей через интернет-сайты, через такие как [1, 2], неуклонно растет. Процесс просмотра интернет ресурсов занимает слишком много времени, ведь выбрать автомобиль с нужными характеристиками или продать его по выгодной цене довольно затруднительно.

Впервые работа о прогнозировании стоимости б/у автомобиля методом нейросетевого моделирования была опубликована в монографии [3]. В эксперименте участвовали автомобили только Волжского автомобильного завода и на входе было пять критериев: модель авто, год выпуска, пробег, наличие антикор. защиты и общее техническое состояние.

На данный момент на просторах интернета уже имеется программная реализация оценки б/у автомобилей с использованием машинного обучения и нейросетевого моделирования, прогнозирующей стоимость б/у автомобиля. Примером может послужить компьютерная программа [4], в которой

учитываются 25 параметров автомобиля, и прогноз стоимости рассчитывается на разный интервал продажи автомобиля.

В настоящей работе методика нейросетевого моделирования [5, 6], применена для построения компьютерной программы, прогнозирующей стоимость автомобиля. В качестве входных данных использовались следующие характеристики автомобиля:

X1 – Марка автомобиля, модель (1 – Chevrolet Cruze, 2 – Ford Focus, 3 – Hyundai Solaris, 4 – Lada Priora, 5 – Mitsubishi Pajero, 6 – Toyota Corolla, 7 – VW Golf, 8 – VW Polo)

X2 – Год выпуска;

X3 – Объем двигателя, л;

X4 – Трансмиссия (Механика – 1, Автомат – 2);

X5 – Тип кузова (внедорожник – 1, купе – 2, седан – 3, универсал – 4, хетчбэк – 5);

X6 – Пробег, км;

X7 – Цвет кузова (белый – 1, голубой – 2, желтый – 3, зеленый – 4, золото – 5, коричневый – 6, красный – 7, серебряный – 8, серый – 9, синий – 10, фиолетовый – 11, черный – 12);

X8 – Привод: монопривод – 1, полный – 2;

X9 – Состояние: 0 – новый автомобиль, 1 – отличное, 2 – царапины, ржавчина, сколы, 3 – мятый, 4 – не на ходу (нужен ремонт), 5 – не подлежит восстановлению;

X10 – Тип топлива: бензин – 1, дизель – 2;

X11 – Количество комплектов резины: 1 или 2;

X12 – Руль: левый – 1, правый – 2.

Далее с помощью нейросимулятора [7] было выполнено проектирование, оптимизация, обучение и тестирование нейронной сети. Оптимальной структурой нейронной сети является персептрон, имеющий 12 входных нейронов, 3 скрытых слоя, первый из которых с 2 нейронами, второй скрытый слой с 3 нейронами и третий скрытый слой с 1 нейроном, а также один выходной нейрон (рис. 1). В качестве активационных функций нейронов скрытого слоя и выходного нейрона использовались функции тангенса гиперболического.




Рисунок 4. Спроектированная нейронная сеть

Для обучения и тестирования была собрана выборка, состоящая из 79 и 21 соответственно опубликованных на auto.ru [1] автомобилей. После обучения и оптимизации нейронной сети среднее квадратичное отклонения тестирования составило 11,95%. При проверке построенной нейросетевой модели разница между компонентами желаемого выходного вектора и действительного выходного вектора была незначительной (рис. 2).




Рисунок 2. График оценки степени достоверности полученных данных при проверке

На основе данных значимости параметров вычисленных нейросетью можно выделить несколько основных параметров (рис. 3):

1. Год выпуска;
2. Привод;
3. Марка автомобиля и модель;
4. Трансмиссия.




Рисунок 3. Диаграмма значимости параметров

Возьмем автомобиль, характеристики которого представлены в таблице 1:

Таблица 1 – Характеристики автомобиля

X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12
1	2011	1.6	1	3	60000	10	1	1	1	1	1

При таких параметрах стоимость автомобиля будет составлять 541067.50 рублей. При увеличении года выпуска можно заметить, что цена автомобиля возрастает (рис. 4).



Рисунок 4. График зависимости цены от года выпуска

В следующем этапе были взяты автомобили с одинаковыми характеристиками за исключением трансмиссии. У первого автомобиля трансмиссия – механика, у второго автомат. Можно заметить, что автомобиль на автоматической коробке передач стоит дороже, чем автомобиль на механической (рис. 5).




Рисунок 5. Зависимость стоимости автомобиля от трансмиссии

Далее были взяты автомобили с одинаковыми характеристиками, но с разным приводом. Было выявлено, что автомобили на полном приводе стоят дороже, чем автомобили, имеющие монопривод (рис. 6).




Рисунок 6. Зависимость стоимости автомобиля от привода

Следующим этапом было решено узнать: какова будет стоимость автомобилей с одинаковыми характеристиками, но разных производителей. В результате было получено, что автомобиль марки Mitsubishi Pajero стоит дороже, чем автомобиль Lada Priora с такими же техническими характеристиками (рис. 7).




Рисунок 7. Зависимость стоимости автомобиля от марки

Библиографический список

1. Авто.ру [Электронный ресурс] // URL: <https://auto.ru>. (Дата обращения: 16.11.2019).
2. Авито.ру [Электронный ресурс] // URL: <https://avito.ru>. (Дата обращения: 16.11.2019).
3. Ясницкий Л.Н., Бондарь В.В., Бурдин С.Н. и др., под ред. Л.Н.Ясницкого. Пермская научная школа искусственного интеллекта и ее инновационные проекты. Москва-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. – С.75.
4. Automama [Электронный ресурс] // URL: <https://automama.ru/ocenka-avto>. (Дата обращения: 17.11.2019).
5. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – С.176.

6. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. С.221.
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

PREDICTION THE COST OF THE CAR BASED ON ITS CHARACTERISTICS

Medvedev Slava S.

National Research University Higher School of Economics, Russia, Perm, 614046,
Students kaya str., 38, steinswriter@gmail.com

This article describes process of development of math model based on neural network simulator for prediction the cost of the car on the basis of its characteristics. The most important characteristics that affect the cost of the car were identified by analyzing the mathematical model

Key words: car, cost, prediction, mathematical model, neural network.

УДК 004.8

ПРОГНОЗИРОВАНИЕ СПРОСА НА АРЕНДУ ВЕЛОСИПЕДОВ С ПОМОЩЬЮ НЕЙРОСЕТЕВОЙ МОДЕЛИ

Копылов Андрей Максимович

Пермский государственный национальный исследовательский университет,
ПМИ. Россия, г. Пермь, 614990, ул. Букирева, 15,
andmaxkopylov@gmail.com

Реализована математическая модель для прогнозирования спроса на основе технологий нейросетевого моделирования, основанная на информации из открытого банка данных. Из исследования выяснено, что наиболее значимыми параметрами являются погодные условия: температура, влажность и скорость ветра. Наименее важным параметром является месяц, в рамках которого происходит прогноз.

Ключевые слова: прогноз; модель; нейронная сеть; аренда; велосипеды; погода.

Введение

В современном мире набирает популярность шеринг – вид совместного пользования, который, по сути, является вариантом той же самой аренды, но с некоторыми отличиями.

Сервисы каршеринга (аренды автомобилей), например, предоставляют своим клиентам достаточно гибкие условия сотрудничества, такие как

возможность арендовать автомобиль в одном отделе, а вернуть его уже в другом.

Подобные сервисы постепенно внедряются и в другие сферы нашей жизни, но наибольшую популярность они получили именно в сфере аренды личного транспорта.

За рубежом и в России уже давно популярен другой вид подобных сервисов, предоставляющих аренду велосипедов. Велосипеды сами по себе являются самым доступным видом личного транспорта, а те же самые гибкие условия аренды позволили таким сервисам быстро найти своих потребителей.

Основной целью работы является создание системы прогнозирования спроса на аренду велосипедов в зависимости от погодных условий. Эти данные позволят владельцам минимизировать затраты, основываясь на результатах прогноза: грамотно выбирать время для проведения планового техобслуживания, приобрести дополнительные велосипеды для максимизации выручки от потенциально прибыльного дня, разумно перемещать велосипеды между пунктами выдачи.

2. Описание модели

Нейронная сеть имеет 8 входных параметров, которые описаны в таблице 1.

Таблица 1 – Описание входных параметров

Вход	Описание
X1	Месяц: принимает значения от 1 до 12.
X2	Является ли текущий день праздничным: 0 – нет, 1 – да.
X3	Текущий день недели: принимает значения от 1 до 7.
X4	Является ли текущий день рабочим (т.е. не выходным и не праздничным): 0 – нет, 1 – да.
X5	Тип погоды: 1 – ясно, 2 – туман, 3 – легкий дождь/снег, 4 – ливень/буран.
X6	Температура. (°C)
X7	Влажность (%)
X8	Скорость ветра (м/с)

Выходной параметр один – нормализованный спрос на велосипеды D_1 , полученный по формуле 1; где q – количество арендованных велосипедов за текущий день, q_{\min} и q_{\max} – минимальное и максимальное количество арендованных велосипедов за всю историю наблюдения соответственно.

$$D_1 = \frac{(q - q_{\min})}{(q_{\max} - q_{\min})} \quad (1)$$

Нейросеть создана и обучена с помощью программного обеспечения «Нейросимулятор 5.0» [1].

3. Структура нейронной сети

Данные для обучения были получены из открытого источника «UCI: Machine Learning Repository» [5]. В результате, для обучающего множества было использовано 514 примеров, для тестового множества – 148 примеров (20% от обучающего множества), для подтверждающего – 75 примеров (10% от обучающего множества).

Воспользуемся следствием из теоремы Арнольда-Колмогорова (формула 2) [2], чтобы найти оптимальное количество нейронов на скрытом слое.

$$\frac{N_y Q}{1 + \log_2 Q} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) \quad (2)$$

В этой формуле: N_y – количество выходных нейронов, N_x – количество входных ней, Q – количество примеров в обучающем множестве, N_w – необходимое число синоптических связей. Полученная оценка: $138 \leq N_w \leq 652,5$.

Найдем оценку для количества скрытых нейронов – N : $15 \leq N \leq 73$. Изучим различные конфигурации скрытого слоя, чтобы установить оптимальное количество нейронов. Результаты исследования можно видеть на рисунке 1.




Рисунок 1 – Результаты поиска оптимального количества нейронов

Таким образом, оптимальной оказалась конструкция нейросети, в которой на скрытом слое находится 61 нейрон, функция активации – сигмоида.

4. Проверка на подтверждающем множестве

В подтверждающее множество входят примеры, не входящие в обучающее и тестовое множества. Следовательно, можно сделать вывод о том, насколько успешно нейронная сеть способна решать задачи в рамках текущей предметной области [3]. Среднее квадратичное отклонение при проверке составило 14%. Результаты сравнения на случайной выборке из подтверждающего множества представлены ниже на рисунке 2.




Рисунок 2 – Сравнение реальных и вычисленных значений

Полученная нейронная сеть успешно справилась с вычислением нормализованного спроса для примеров из подтверждающего множества. Это значит, что данную сеть теперь можно использовать для получения практической информации.

Существует несколько способов определения важности входных параметров [2, 3]. Например, одним из способов является поочередное исключение входных параметров и дальнейшее наблюдение за изменениями погрешности. Так же аналогичный функционал присутствует в инструментарии ПО «Нейросимулятор 5» [1], которым мы и воспользуемся. Результаты представлены на рисунке 3.




Рисунок 3 – Значимость параметров полученной нейросети

Теперь у нас имеется вся необходимая информация для проведения экспериментов с помощью данной нейросети.

5. Извлечение практических знаний

Используя полученные данные, легко установить, что на спрос, главным образом влияют погодные факторы: скорость ветра, температура воздуха и влажность. Влияние оказывает так же и сам тип погоды, но не настолько большое.

Рассмотрим для примера, вторник 19 июня прошлого года. Воспользовавшись погодным сервисом «weather.com» [6], получаем данные, представленные на таблице 2.

Таблица 4.1 – Значения входов/выходов для 19 июня 2019 г

Вход	X1	X2	X3	X4	X5	X6	X7	X8	D1
Значение	6	0	2	1	1	28	48	10	0,7872

Загрузив эти данные нейросеть, будем проводить эксперименты: изменять входы, отвечающие за параметры температуры, влажности, скорости ветра и типа погоды. Будем также фиксировать изменения для проведения дальнейшего анализа.

Тип погоды закономерно имеет большое влияние на спрос, как это видно на рисунке 4. Были рассмотрены варианты всех возможных типов погоды: ясной, туманной, легкого дождя и ливня.




Рисунок 4 – Влияние типа погоды на спрос

График влияния температуры на спрос представлен на рисунке 5 ниже. Ожидаемо, температура имеет очень высокое влияние на спрос. Был рассмотрен диапазон от 28 до -10 градусов Цельсия.




Рисунок 5 – Влияние температуры воздуха на спрос

Теперь изучим влияние влажности на потенциальный спрос на велосипеды. Т.к. влажность измеряется в процентах, рассмотрим весь возможный диапазон – от 0% до 100%. Влажность оказывает сильное влияния на спрос, как ожидалось. Результаты можно увидеть на рисунке 6 ниже.




Рисунок 6 – Влияние влажности воздуха на спрос

Еще одним немаловажным параметром является скорость ветра. Точно так же, чтобы изучить, как скорость ветра влияет на спрос, зафиксируем все остальные параметры и пройдемся по диапазону от 1 до 50 метров в секунду. Результаты представлены ниже, на рисунке 7.




Рисунок 7 – Влияние скорости ветра на спрос

6. Заключение

Реализована математическая модель на основе технологий нейросетевого моделирования. Система, основываясь на погодных данных, позволяет владельцам сервисов по аренде велосипедов предсказывать спрос на свои услуги. Таким образом, владельцы могут планировать плановое техобслуживание на дни, когда спрос не ожидается высоким. Или, например,

проводить различные акции и прочие мероприятия в дни, когда спрос ожидается высоким, чтобы максимально увеличить выручку.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
2. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007. – 271 с.
3. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. – 221с.
4. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5. – С. 48-56.
5. Открытый банк данных «UCI» // url: archive.ics.uci.edu
6. Метеорологический сервис «The Weather Channel» // url: weather.com

PREDICTING DEMAND FOR RENT BICYCLES USING A NEURAL NETWORK MODEL

Kopylov Andrey M.

Perm State National Research University, PMI.
Russia, Perm, 614990, Bukireva st., 15,
andmaxkopylov@gmail.com

A mathematical model was implemented to forecast demand based on neural network modeling technologies, based on information from an open data bank. From the study it was found that the most significant parameters are weather conditions: temperature, humidity and wind speed. The least important parameter is the month within which the forecast occurs.

Key words: forecast; prediction; model; neural network; rent; bicycles; weather.

АНАЛИЗ КАЧЕСТВА КРАСНОГО ВИНА ПО ЕГО ФИЗИКО-ХИМИЧЕСКИМ ПАРАМЕТРАМ

Федоровых Алексей Дмитриевич

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, aleshka-f2000@yandex.ru

В статье представлено описание разработки нейросетевой системы для исследования зависимости качества красного португальского вина "Vinho Verde" от его физико-химических параметров. Система позволяет выявить важнейшие параметры, влияющие на качество алкогольного напитка, и определить их значения для получения наилучшей качественной оценки.

Ключевые слова: искусственный интеллект, нейросетевые технологии, вино, самоадаптация, оценка качества, прогнозирование, качество вина, алкоголь.

Введение. Дегустация всегда лидировала среди способов оценки продукции, в частности, вина. Данный способ остается основным и по сей день. Однако человек не может предсказать, какие параметры при производстве вина являются важными, что нужно поменять в процессе изготовления, чтобы улучшить качество алкогольного напитка.

При использовании нейросетевых технологий этот процесс можно автоматизировать, и исключить вмешательство человека из оценивания вина.

Основная цель настоящей работы заключается в сборе множества данных о параметрах изготовленных вин, создание и обучение нейросетевой модели на этих данных, а также выявление конкретных знаний в предметной области.

Для обучения и тестирования модели используются данные с электронного ресурса [5] размерностью 1298(80%) примеров и 301(20%) пример соответственно.

Входными параметрами для модели будут являться следующие характеристики:

- Фиксированная кислотность – от 4,6 до 15,9
- Летучая кислотность – от 0,12 до 1,58
- Лимонная кислота – от 0 до 1
- Остаточный сахар – от 0,9 до 15,5
- Хлориды – от 0,01 до 0,61
- Свободный диоксид серы – от 1 до 72
- Общий диоксид серы – от 6 до 289
- Плотность – от 0,99 до 1
- pH – от 2,74 до 4,01

- Сульфаты – от 0,33 до 2
- Алкоголь – от 8,4 до 14,9

Выходной параметр только один – качество вина (от 3 до 8).

Проектирование, обучение и тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5». В результате оптимизации спроектированная нейронная сеть представляет собой персептрон, который имеет одиннадцать входных нейронов, один выходной и один скрытый слой с восемью нейронами.

Средняя ошибка обучения составила 12%, в то время как средняя ошибка тестирования была равна 13%, что можно считать хорошим результатом. На рисунке 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью качеством случайно отобранного 31 вина из тестирующего множества.




Рисунок 1. Результат тестирования нейронной сети

Из результатов, изображенных на рисунке 1, можно сделать вывод об адекватной работе спроектированной нейронной сети в нашей предметной области.

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рисунке 2.




Рисунок 2. Значимость входных параметров нейросетевой модели

Как видно из рисунка 2, наиболее значимыми являются крепость алкоголя, сульфаты, общий диоксид серы и т.д.

Также были рассчитаны коэффициенты корреляции Пирсона между входными параметрами и выходным, которые показывают, насколько сильно выходной параметр зависит не только от одного входного параметра, но и от других. Результат представлен на рисунке 3 в виде гистограммы.




Рисунок 3. Значения модулей коэффициентов корреляции Пирсона между входными параметрами и качеством вина

Далее было проведено исследование модели методом «замораживания», при котором происходит наблюдение за изменением выходного параметра

при изменении значений одного входного параметра, в то время как остальные входные параметры имеют фиксированные значения. Данный метод позволяет выявить оптимальное значение параметра для достижения лучшего результата выходного параметра. Проверим влияние самых важных показателей на качество четырех заранее отобранных случайным образом винных изделий.

На рисунке 4 изображен график зависимости качества вина от процента содержания в нем алкоголя. В качестве значений крепости алкоголя были взяты числа от 8,4 до 14,9 с шагом в 0,5. Из полученного графика можно увидеть, что вино более высокого качества получится при увеличении процента алкоголя.




Рисунок 4. Зависимость качества вина от крепости алкоголя

На следующих рисунках можно увидеть, что качество вина достигает своего максимума на крайних значениях параметров.




Рисунок 5. Зависимость качества вина от сульфатов




Рисунок 6. Зависимость качества вина от общего диоксида серы

На рисунке 7 качество вина достигает своего апогея при значении рН, находящемся в окрестности значения 3,22.




Рисунок 7. Зависимость качества вина от pH

Заключение. Построена система нейросетевого оценивания качества красного португальского вина "Vinho Verde". Спроектированная нейросетевая модель учитывает одиннадцать физико-химических показателей, влияющих на качество напитка. Проведены исследования работы данной модели в рамках предметной области, в которой эта модель работает корректно. Посредством прогнозирования были выявлены знания полезные для производства вина, а именно: были построены графики зависимостей качества вина от крепости алкоголя, сульфатов, общего диоксида серы и pH.

Библиографический список

1. Черепанов Ф.М. Симулятор нейронных сетей для вузов. Пермь, 2012.
2. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 224 с.
3. Ясницкий Л.Н., Черепанов Ф.М. Искусственный интеллект: лабораторный практикум. URL: <http://www.lbai.ru/> (дата обращения: 20.06.2020).
4. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
5. Открытые наборы данных для машинного обучения. URL: <https://www.kaggle.com/> (дата обращения: 20.06.2020).
6. Сидорина С.А. Воронова Л.И. Применение методов интеллектуального анализа данных в задаче классификации экспертных оценок качества винных изделий. Научное обозрение. Педагогические науки. – 2019. – № 4 (часть 3) – С. 76-78.
7. Костюшева Д.В. Прогнозирование качества красного вина на основе химических показателей [Электронный ресурс]. Пермь 2018.

8. Щелкунов А.А. Прогнозирование оценки качества вина методом нейросетевого моделирования [Электронный ресурс]. Пермь, 2018.

RED WINE QUALITY ANALYSIS BY ITS PHYSICAL AND CHEMICAL PARAMETERS

Fedorovykh Alexey D.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, aleshka-f2000@yandex.ru

The article describes the development of a neural network system to study the dependence of the quality of red Portuguese wine "Vinho Verde" on its physicochemical parameters. The system allows you to identify the most important parameters that affect the quality of an alcoholic beverage, and determine their values to obtain the best quality score.

Key words: artificial intelligence, neural network technologies, wine, self-adaptation, quality assessment, forecasting, wine quality, alcohol.

УДК 004.032.26

ПРЕДСКАЗАНИЕ НАЛИЧИЯ ОСЛОЖНЕНИЙ ПОСЛЕ ОПЕРАЦИИ УДАЛЕНИЯ ОСТРОГО АППЕНДИЦИТА

*Савенков Константин Евгеньевич, Горбаченко Владимир Иванович,
Соломаха Анатолий Анатольевич*

Пензенский государственный университет, ПГУ
440026, Россия, г. Пенза, ул. Красная, 40, gorvi@mail.ru

В статье представлено описание разработки нейросетевой системы предсказания наличия осложнений после удаления острого аппендицита. Предложены способ кодирования составных признаков и отбора признаков на основе интерквартильного размаха метрики качества работы сети. Произведена подготовка обучающего набора. Экспериментально подобрана архитектура нейронной сети глубокого обучения. Для предотвращения переобучения сети применен метод dropout регуляризации сети. Сеть обучена с использованием градиентного алгоритма Adam с адаптивной скоростью обучения. Результаты экспериментов выявили высокие показатели качества работы сети, превосходящие показатели популярных моделей машинного обучения.

Ключевые слова: предсказание, осложнения, острый аппендицит, кодирование признаков, отбор признаков, нейронные сети, глубокое обучение.

Гнойно-воспалительные осложнения после операции удаления острого аппендицита встречаются у 2,7–39,1% пациентов, смертность от острого аппендицита составляет от 0,1% до 1,6% [1]. Прогнозирование послеоперационных осложнений аппендицита представляет сложную задачу, для решения которой перспективно применение моделей машинного обучения, в частности, нейронных сетей. В [2–3] разработаны искусственные нейронные сети, которые диагностируют наличие острого аппендицита, но отсутствуют математические модели, позволяющие прогнозировать осложнения после удаления аппендицита. Поэтому целью работы является разработка глубокой нейронной сети для прогнозирования осложнений после операций по поводу острого аппендицита.

В качестве исходных данных использован набор данных зарегистрированной базы данных [4]. Набор данных содержит 108 записей. Из них 70 записей соответствуют операциям без осложнений, 38 записей соответствуют операциям с различными осложнениями. Набор представлен в виде таблицы, имеющей 30 признаков с анализами крови до и после операции и 12 общих признаков, например, возраст, группа крови и так далее. Так как стоит задача прогнозирования состояния до операции, то используем анализы крови до операции: гемоглобин; эритроциты; цветовой показатель; лейкоциты; нейтрофилы палочкоядерные; нейтрофилы сегментоядерные; лимфоциты; моноциты; скорость оседания эритроцитов; общий билирубин; общий белок; амилаза; мочевины; креатинин; глюкоза. Используем также общие признаки, известные до операции: пол; возраст; койко-день; группа крови и резус-фактор; основной диагноз; сопутствующий диагноз; длительность оперативных вмешательств; электрокардиограмма (ЭКГ); клиническая оценка состояния больного; наличие осложнений.

Для подготовки данных для обучения использована библиотека `pandas` [5]. Набор данных содержит небольшое количество пропусков, поэтому признаки с пропусками было решено отбросить, из-за сложности их заполнения. Был также исключен признак "койко-день", показывающий общее количество дней в больнице, но не день, когда произведена операция. В результате получено множество признаков: пол; возраст; основной диагноз; гемоглобин; эритроциты; лейкоциты; нейтрофилы палочкоядерные; лимфоциты; наличие осложнений.

Нейронные сети работают только с числами. Поэтому бинарные и категориальные (качественные) признаки и целевые значения должны кодироваться. При кодировании бинарных признаков "ложь" кодировалась как "0", а "истина" – как "1". Для кодирования качественных переменных использовался унитарный код (One-Hot Encoding) [6]. В таком случае, если категориальный признак принимает n значений, то он заменяется вектором из n значений. В строках таблицы исходных данных рассматриваемый признак заменяется признаками, все из которых равны нулю, за исключением одного. На позиции, соответствующей номеру значения признака, размещается 1. Признак "основной диагноз" является составным, часть пациентов имеют два диагноза одновременно: острый флегмозный

аппендицит; острый катаральный аппендицит, тифлит; острый аппендицит; острый катаральный аппендицит; острый гангренозный аппендицит; острый катаральный аппендицит, острый аппендицит; острый деструктивный аппендицит; острый гангренозный перфоративный аппендицит. Кодирование признака "основной диагноз" унитарным кодом приводит к большой избыточности. Авторами предложен подход к кодированию составных признаков. Для этого выделяются простые признаки, в нашем случае их будет 8. Признак "основной диагноз" заменяется бинарными признаками, число которых равно количеству простых признаков. Бинарный признак принимает значение "1" при наличии соответствующего диагноза. Для масштабирования числовых признаков на отрезок $[0, 1]$ использовано масштабирование по минимуму.

Для упрощения обучения модели был произведен отбор наиболее важных признаков. Для отбора признаков предложен алгоритм отбора признаков на основе метода "обертки" [7] с использованием интерквартильного размаха показателей качества модели. Необходимо из 8 признаков: пол; возраст; основной диагноз; гемоглобин; эритроциты; лейкоциты; нейтрофилы палочкоядерные; лимфоциты выбрать набор признаков, обеспечивающий высокое значение метрики качества работы модели. Процесс обучения моделей машинного обучения имеет случайный характер: инициализация начальных параметров, как правило, подразумевает использование случайного алгоритма; во время обучения, обучающая выборка перемешивается случайным образом; и тому подобное. Использование M экспериментов позволит избежать влияния на результат отбора множества случайных факторов. Во время процесса отбора признаков каждая модель обучается M раз на каждой комбинации признаков. Результаты обученной модели представляются в виде значений какой-либо метрики качества и записываются в таблицу. В качестве метрики, применим F_1 -меру. Данная метрика является средним гармоническим прецизионности (precision) и полноты (recall) [8]. Для получения стабильной оценки метрики использован интерквартильный размах [8]. Среднее арифметическое метрики качества является неустойчивым и сильно зависит от предельных значений выборки. В качестве лучшей используется комбинация признаков, обеспечивающая наименьший разброс F_1 -меры. В качестве меры разброса метрики используем интерквартильный размах – разницу между 0,25 и 0,75 квантилями [8]. Алгоритм начинает работу с выбора начального признака, к которому путём перебора добавляются оставшиеся признаки из списка. По результатам обучения 8 моделей, в качестве базового признака был выбран признак "основной диагноз". Далее был произведён отбор наиболее значащей комбинации признаков. Лучший значение F_1 -меры обеспечила комбинация признаков: основной диагноз, пол, возраст, эритроциты. Отбор признаков производился с помощью финальной модели машинного обучения, описанной ниже.

В качестве библиотеки для реализации архитектуры нейронной сети была выбрана библиотека Keras [9]. Библиотека Keras является надстройкой над фреймворком TensorFlow [10] и значительно облегчает использование такого достаточно сложного инструмента. После ряда экспериментов с различными архитектурами, функциями активации, методами обучения и видами нейронов была выбрана глубокая нейронная (рисунок 1).

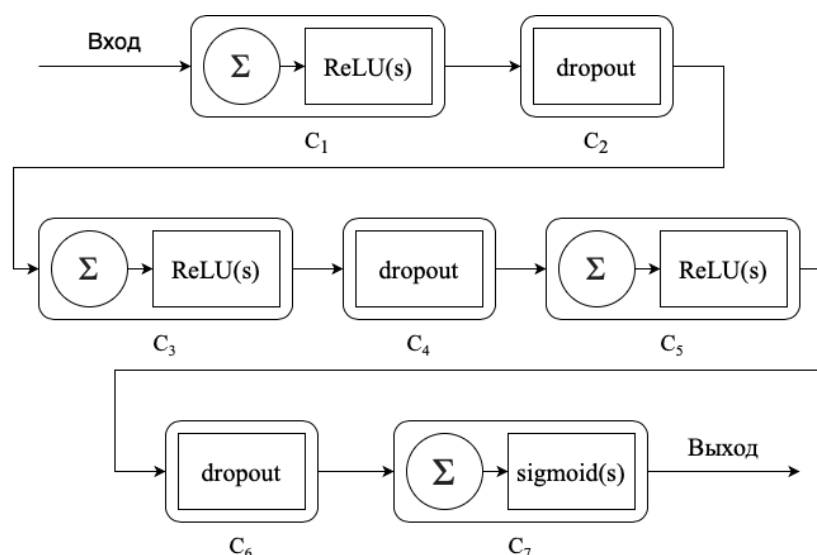


Рисунок 1. Архитектура классификатора, построенная с использованием метода «прореживания» нейронов (dropout).

В слоях C_1 , C_3 , C_5 , C_7 в качестве функции обработки применяется сумматор, вычисляющий взвешенную сумму $s = \sum_i w_i x_i$, где w_i и x_i – i -е компоненты, соответственно, вектора весов и входного вектора. Функции активации слоёв различаются. В качестве функций активации скрытых слоёв (C_1 , C_3 , C_5) применяется функция ReLU (Rectified Linear Unit) – положительная линейная функция активации, или жёсткий максимум [10]. В отличие от сигмоидальных функций активации, функция ReLU легко вычисляется, что важно для сложных сетей. Производная от этой функции равна либо 1, либо 0, что исключает "паралич" нейронной сети. В выходном слое используется асимметричная логистическая функция активации. Данная функция хорошо подходит в качестве выходной функции активации, так как она распределена от 0 до 1, что можно трактовать как вероятность наличия осложнений. Количество нейронов в слоях классификатора определялось по формуле $N = kn$, где k – коэффициент, n – размерность входного вектора.

Во избежание появления проблемы переобучения применялся метод регуляризации dropout – прореживание нейронов [10]. Экспериментальным путём, был настроен параметр p – уровень отключения нейронов: для слоя C_2 порог $p = 0.30$; для слоя C_4 порог $p = 0.15$; для слоя C_6 порог $p = 0.05$.

Так как производилось обучение сети с разным количеством признаков для последующего отбора лучшей комбинации с помощью интерквартильного размаха, то количество нейронов в слоях классификатора определялось в зависимости от размерности входного вектора, что позволило автоматизировать перебор различных комбинаций признаков.

Коэффициенты k были экспериментально подобраны и равны: для слоя C_1 коэффициент $k=1,0$; для слоя C_3 коэффициент $k=0,5$; для слоя C_5 коэффициент $k=0,2$. В слое C_7 имеется один нейрон, определяющий наличие осложнений. В качестве выходной функции активации классификатора использовалась сигмоидальная функция, значение которой распределено от 0 до 1. Для классификации подобран порог отсечения, равный 0,4. Значения большие или равные 0,4 интерпретируются нами, как 1 – наличие осложнений, а меньшие 0,4, как 0 – отсутствие осложнений.

Классификатор обучался методом Adam (adaptive moment estimation) [11]. Данный метод обучения имеет адаптивный параметр – скорость обучения для каждого веса. Благодаря особенностям метода, можно избежать попадания в часть локальных минимумов. Для инициализации начальных параметров модели использовался метод Ксавье (Xavier initialization) [12].

Малое количество данных вынудило авторов для оценки метрик качества работы сети использовать кросс-валидацию по k блокам [10]. В качестве реализации использовался класс StratifiedKFold из библиотеки Scikit-learn. Особенность данной реализации заключается в формировании стратифицированных подвыборок. Для обучения классификатора набор данных был разделен на 10 поднаборов.

При обучении модели машинного обучения применялся callback-метод библиотеки Keras [13]. Данный метод применяется итеративно, на каждой итерации. В случае, если на текущей итерации значение выбранной метрики качества классификатора изменилось в худшую сторону, параметры модели не будут обновлены на новые и останутся прежними. Данный подход применяется для того, чтобы на каждой итерации алгоритм обучения работал с лучшей моделью и в итоге была получена наиболее эффективная модель машинного обучения.

Эксперименты проводились на компьютере с процессором 2,4 GHz Intel Core i5 с 8ГБ 1600 MHz DDR3 оперативной памяти под управлением операционной системы macOS Mojave с версией 10.14.6. В качестве языка реализации был выбран Python, версии 3.7.3. Использовались следующие библиотеки: Scikit-Learn версии 0.22.2.post1, TensorFlow версии 2.1.0, NumPy версии 1.17.0, Keras версии 2.3.1. Время обучения классификатора составило 11 секунд на одну итерацию кросс-валидации.

При проведении экспериментов рассчитывались следующие метрики качества [8, 10]:

Прецизионность (Precision) – точность ("аккуратность") предсказания положительного исхода, т. е. какая доля объектов, выделенных

классификатором как положительные, действительно является положительными

$$R_{PR} = \frac{N_{TP}}{N_{TP} + N_{FP}}.$$

Чувствительность (Sensitivity) – это доля истинно положительных примеров, правильно определенных классификатором

$$S_R = \frac{N_{TP}}{N_{TP} + N_{FN}}.$$

Специфичность (Specificity) оценивает способность классификатора предсказывать отрицательный исход

$$S_P = \frac{N_{TN}}{N_{TN} + N_{FP}}.$$

В приведенных метриках использованы следующие обозначения: N_{TP} – число истинно положительных наблюдений, N_{TN} – число истинно отрицательных наблюдений, N_{FP} – число ложно положительных наблюдений, N_{FN} – число ложно отрицательных наблюдений, $N = N_{TP} + N_{TN} + N_{FP} + N_{FN}$ – общее число наблюдений.

Хороший классификатор должен обеспечивать высокие показатели точности и полноты. Но достичь одновременно максимальных значений точности и полноты нельзя. Поэтому для экспериментов с классификаторами необходима единая метрика, объединяющая точность и полноту. Такой метрикой является *F-мера* (*F-score*). Используется два вида F-меры. F_1 является гармоническим средним между прецизионностью и полнотой

$$F_1 = 2 \frac{R_{PR} * S_R}{R_{PR} + S_R}.$$

Мера F_1 будет близка к нулю, если хотя бы из ее аргументов близок к нулю. Причем прецизионность и полнота оказывают одинаковое влияние.

Рассчитывалась также площадь под ROC-кривой (AUC – Area Under ROC Curve).

Результаты экспериментов представлены в таблице 1.

Таблица 1 – Результаты экспериментов

Метрика	Значения метрик	
	Среднее	Медиана
Прецизионность	0,8210	0,8333
Чувствительность	0,7893	0,8571
F1-мера	0,7994	0,7778
Специфичность	0,8896	0,9167
ROC AUC	0,8402	0,8622
Вероятность ошибки I рода	0,2333	0,1667

Вероятность ошибки II рода	0,1270	0,0769
-------------------------------	--------	--------

Полученные значения метрик модели не идеальны, но существенно превосходят метрики других исследованных моделей машинного обучения (таблица 2).

Таблица 2 – Результаты обучения различных моделей

Алгоритм	Прецизионность	F ₁ -мера
Логистическая регрессия	0,6500	0,5148
Деревья решений	0,6605	0,5968
Случайный лес	0,7383	0,5957
Многослойный перцептрон	0,8210	0,7994

При наличии достаточного объёма данных, построенная архитектура может послужить хорошей основой для создания более сложной модели машинного обучения.

Библиографический список

1. A meta-analysis comparing conservative treatment versus acute appendectomy for complicated appendicitis (abscess or phlegmon) / C. Simillis, P. Symeonides, F. J. Shorthouse, P. P. Tekkis // *Surgery*. 2010. No 147. P. 818–829.
2. Park S. Y., Kim S. M. Acute appendicitis diagnosis using artificial neural networks / *Technology and health care*. 2015. Vol. 23. P. 559–565.
3. Artificial neural Networks: Useful Aid in Diagnosing Acute Appendicitis / S. G. Prabhudesai, S. Gould, S. Rekhraj, P. P. Tekkis, G. Glazer, P. Ziprin // *World Journal of Surgery*. Vol. 32. No 2. P. 305–309.
4. Клинико-лабораторные параметры больных острым аппендицитом / П. А. Ващенко, А. А. Соломаха, В. И. Горбаченко, А. О. Хазратов // Свидетельство о государственной регистрации базы данных № 2014621431. Дата государственной регистрации в Реестре баз данных 10 октября 2014 г.
5. Хейд М., Груздев А. В. Изучаем pandas. М.: ДМК Пресс, 2019. 682 с.
6. Brownlee J. Why One-Hot Encode Data in Machine Learning? [Электронный ресурс]. URL: <https://machinelearningmastery.com/why-one-hot-encode-data-in-machine-learning/> (дата обращения: 27.09.2020).
7. Zheng A., Casari A. Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists. – O'Reilly Media, 2018. – 218 p.

8. Брюс П., Брюс Э. Практическая статистика для специалистов Data Science. – СПб.: БХВ-Петербург, 2018. – 304 с.
9. Шолле Ф. Глубокое обучение на Python. – СПб.: Питер, 2018. – 400 с.
10. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow. Концепции, инструменты и техники для создания интеллектуальных систем. – СПб.: ООО «Альфа-книги», 2018. – 688 с.
11. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. [Электронный ресурс]. URL: <https://arxiv.org/abs/1412.6980> (дата обращения: 27.09.2020).
12. Glorot X., Bengio Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks // International conference on artificial intelligence and statistics, 2010. – P. 249–256.
13. Keras: The Python Deep Learning library. Usage of callbacks. [Электронный ресурс]. URL: <https://keras.io/callbacks/> (дата обращения: 27.09.2020).

PREDICTION OF COMPLICATIONS AFTER REMOVAL OF ACUTE APPENDICITIS

Savenkov Konstantin E., Gorbachenko Vladimir I., Solomakha Anatoly A.

Penza State University, PSU

440026, Russia, Penza, st. Krasnaya, 40, gorvi@mail.ru

The article describes the development of a neural network system for predicting the presence of complications after acute appendicitis removal. A method for coding composite features and feature selection based on the interquartile range of the network performance metric is proposed. A training set has been prepared. The architecture of a deep learning neural network is experimentally selected. To prevent overfitting of the network, the dropout method of network regularization is applied. The network is trained using the Adam gradient algorithm with adaptive learning rate. The results of the experiments revealed high performance indicators of the network, exceeding those of popular machine learning models.

Key words: prediction, complications, acute appendicitis, feature coding, feature selection, neural networks, deep learning.

ИСПОЛЬЗОВАНИЕ ЦИФРОВОГО ДВОЙНИКА ПРИ УПРАВЛЕНИИ ЭНЕРГОСИСТЕМАМИ, ВКЛЮЧАЮЩИМИ АЭС ИЛИ ТЭС В УСЛОВИЯХ СНИЖЕНИЯ ДОСТОВЕРНОСТИ ДАННЫХ, ПОСТУПАЮЩИХ ОТ ОБОРУДОВАНИЯ

Грабчак Евгений Петрович, Логинов Евгений Леонидович

Министерство энергетики Российской Федерации, 107996, Россия, Москва, ул. Щепкина, д.42, стр.1, loginovel@mail.ru

В статье рассматриваются проблемы использования цифрового двойника как комплекса цифровых моделей работы функциональных узлов оборудования для поддержания стабильности управления распределенными энергосистемами, включающими АЭС или ТЭС при временном снижении достоверности информации о работе функциональных узлов оборудования. Для улучшения управления в условиях получения недостоверных данных об идущих технических процессах обоснована необходимость определения достоверности информации, поступающей от функциональных узлов оборудования, полученных от датчиков с расширенной интеллектуальной компонентой. Предлагается анализ команд, запросов, сигналов для фильтрации недостоверных цифровых данных и выработки командных сигналов, соответствующих параметрам цифровой модели работы функционального узла. Осуществляется выработка замещающих [недостоверные] цифровых команд, ориентирующих параметры работы оборудования в оптимальном технологическом режиме как вычислительному результату работы цифровой модели функционального узла.

Ключевые слова: АЭС, ТЭС, информационная система, оборудование, анализ, фильтрация, синтез, мониторинг.

Введение

Разработка технологии поддержания стабильности управления распределенными энергосистемами, включающими атомные электростанции (АЭС) или тепловые электростанции (ТЭС) при временном снижении достоверности информации, поступающей от функциональных узлов оборудования, является актуальной и практически значимой задачей [1-3].

Решение этой задачи может быть решено путем внедрения цифрового двойника технологических процессов (как комплекс цифровых моделей работы функциональных узлов оборудования) с учетом вероятности воздействий случайного (природного) или умышленного (военного и т.п.) характера для улучшения управления через анализ и фильтрацию цифровых технических данных, используемых для выработки командных сигналов при управлении работой оборудования объектов распределенных энергосистем, включающих АЭС или ТЭС [4-6].

Использование цифрового двойника технологических процессов

На основании моделирования процессов работы оборудования в рамках цифрового двойника технологических процессов может быть реализован мониторинг достоверности информации, поступающей от функциональных узлов оборудования [7]. Комплекс моделей цифрового двойника позволяет снизить вероятность нестандартных ситуаций и принятие управляющим звеном управленческих решений, ведущих к ошибочным технологическим режимам, негативно влияющим на стабильность работы оборудования [8].

Для поддержания стабильности управления необходимо решить следующие задачи:

- разработать цифрового двойника технологических процессов в отношении объектов распределенных энергосистем, включающих АЭС или ТЭС;

- разработать информационно-управляющую систему на основе технологии фильтрации цифровых технических данных, используемых для выработки командных сигналов, воздействий случайного (природного) или умышленного (военного и т.п.) характера для управления оборудованием объектов распределенных энергосистем, включающих АЭС или ТЭС;

- разработать подсистему определения достоверности информации, поступающей от функциональных узлов оборудования на базе технологии фильтрации цифровых технических данных, используемых для выработки командных сигналов;

- разработать сервисы расчета параметров работы оборудования в оптимальном технологическом режиме как вычислительного результата работы цифровой модели функционального узла в рамках работы цифрового двойника при управлении работой оборудования объектов распределенных энергосистем, включающих АЭС или ТЭС;

- разработать подсистему выработки замещающих [недостоверные] цифровых команд, ориентирующих параметры работы оборудования в оптимальном технологическом режиме.

Характеристики разрабатываемого цифрового двойника технологических процессов

В рамках цифрового двойника технологических процессов должна быть предусмотрена возможность моделирования и прогнозирования параметров работы оборудования в различных технологических режимах как в обычных, так и нестандартных ситуациях в отношении работы оборудования объектов распределенных энергосистем, включающих АЭС или ТЭС [9].

Развиваемая система цифрового двойника технологических процессов должна включать базу данных с набором стандартных технологических ситуаций и пакета команд, позволяющих привести систему к стабильному технологическому режиму с учетом вероятности зашумленности каналов связи, искажения поступающих данных или замедления работы вычислительного блока обработки данных и моделирования [10].

Заключение

Для дальнейшего развития цифрового двойника технологических процессов необходима реализация следующих мероприятий:

1. Разработка методики фильтрации цифровых технических данных, используемых для выработки командных сигналов для фильтрации недостоверных цифровых данных и выработки командных сигналов для конкретной технической подсистемы, которая позволит создавать мониторинговые подсистемы соответствующие параметрам цифровой модели работы функциональных узлов, интегрированных в рамках цифрового двойника.

2. Разработка специализированных информационно-управляющих сервисов на основе технологии фильтрации цифровых технических данных, используемых для выявления недостоверной информации, полученной от датчиков с расширенной интеллектуальной компонентой для выявления воздействий случайного (природного) или умышленного (военного и т.п.) характера.

3. Разработка специализированных сервисов для синтезирования замещающих [недостоверные] цифровых команд, ориентирующих параметры работы оборудования в оптимальном технологическом режиме как вычислительному результату работы цифровой модели функционального узла в рамках работы цифрового двойника.

Библиографический список

1. *Гвоздев Д.Б., Болонов В.О., Окнин Е.П., Здирук К.Б., Кузьминов И.М.* О возможности применения цифровых двойников в управлении объектами электроэнергетики // *Электроэнергия. Передача и распределение.* 2019. № 6 (57). С. 30-35.
2. *Апканеев А.В.* Стратегические направления совершенствования системы управления предприятиями атомной отрасли // *Вестник экономической интеграции.* 2010. № 7. С. 47-52.
3. *Логинов Е.Л., Логинов А.Е.* Интеллектуальная электроэнергетика: новый формат интегрированного управления в единой энергетической системе России // *Национальные интересы: приоритеты и безопасность.* 2012. Т. 8. № 29 (170). С. 28-32.
4. *Иванов С.Н.* Энергосбережение: проблемы достижения энергоэффективности. М.: Национальный институт энергетической безопасности, 2009. – 329 с.
5. *Грабчак Е.П., Логинов Е.Л.* Цифровые подходы к управлению объектами электро- и теплоэнергетики с применением интеллектуальных киберфизических систем // *Надежность и безопасность энергетики.* 2019. Т. 12. № 3. С. 172-176.
6. *Романова Ю.А.* Проблемы замены изношенного оборудования в электроэнергетике России: приоритеты модернизации в контексте обеспечения надежности и безопасности // *Проблемы безопасности и чрезвычайных ситуаций.* 2019. № 5. С. 38-43.

7. *Массель Л.В., Массель А.Г., Копайгородский А.Н.* Эволюция технологий исследований энергетики и применения их результатов: от математических моделей и компьютерных программ к цифровым двойникам и цифровым образам // Информационные и математические технологии в науке и управлении. 2019. № 4 (16). С. 5-19.
8. *Семенов П.В., Семишкур Р.П., Дяченко И.А.* Концептуальная модель реализации технологии "цифровых двойников" для предприятий нефтегазового комплекса // Газовая промышленность. 2019. № 7 (787). С. 24-30.
9. *Брук П.* Цифровые двойники, основанные на симуляции мультифизических процессов // САПР и графика. 2019. № 7 (273). С. 24-26.
10. *Белокрылов П.Ю., Большухин М.А., Комиссаров К.В., Петрунин В.В., Повереннов Е.Ю.* Интеграция процесса расчетного обоснования оборудования реакторных установок в единое информационное пространство для создания цифровых двойников ЯЭУ // Атомная энергия. 2019. Т. 127. № 6. С. 309-315.

USE OF THE DIGITAL DOUBLE WHEN MANAGING POWER SYSTEMS INCLUDING A NUCLEAR OR A TPP UNDER CONDITIONS OF DECREASING THE DURABILITY OF DATA COMING FROM EQUIPMENT

Grabchak Evgeny P., Loginov Evgeny L.

Ministry of Energy of the Russian Federation, p. 1, d.42, ul. Shchepkina, Moscow, 107996, Russia, loginovel@mail.ru

The article discusses the problems of using a digital double as a complex of digital models of operation of equipment functional units to maintain stability of control of distributed power systems, including nuclear power plants or thermal power plants, while temporarily reducing the reliability of information on the operation of equipment functional units. To improve control in the conditions of obtaining inaccurate data on ongoing technical processes, the necessity of determining the reliability of information received from the functional components of the equipment received from sensors with an extended intellectual component is substantiated. The analysis of commands, queries, signals for filtering false digital data and generating command signals corresponding to the parameters of the digital model of the functional unit. The development of replacement [unreliable] digital commands is being carried out, orienting the parameters of the equipment in the optimal technological mode as the computational result of the digital model of the functional unit.

Key words: nuclear power plants, thermal power plants, information system, equipment, analysis, filtration, synthesis, monitoring.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ГЛАЗАМИ ИНТЕЛЛЕКТУАЛЬНОГО ОБЫВАТЕЛЯ

Данилевич Татьяна Васильевна

Пермский государственный гуманитарно-педагогический университет
614990, г. Пермь, ул. Сибирская, 24, yasn@psu.ru

В статье ставятся и обсуждаются вопросы места искусственного интеллекта в нашей жизни, взаимоотношений человека с искусственным интеллектом, обсуждаются вопросы его будущего развития. Изложение ведется как «взгляд со стороны» обывателя.

Ключевые слова: искусственный интеллект, Homo Sapientissimus, разум, эволюция, прогресс.

«Во всякой мудрости много печали», «Горе от ума». Почему человек в течение жизни приходит к такому выводу? Казалось бы, что может быть выше «ума» и «мудрости», ведь и «ум» и «мудрость» являются олицетворением цивилизационного прорыва человечества, ибо только благодаря им мы достигли научного и технического совершенства в 21-м веке. Впрочем, совершенства ли? Научно-технические достижения безграничны. Пока. Здесь тоже существуют сомнения.

А сейчас техническое оснащение быта и производства невероятно облегчили нашу жизнь. Так чем же мы недовольны? К своему удивлению, мы обнаружили, что за комфорт надо платить и нам это не нравится. Но изменить ситуацию мы не можем: ничего даром не дается получая, мы должны отдавать. И расплачиваемся мы гибелью природы, ухудшением своего здоровья и, в конечном счете, оскудением своих душ.

Но. В дуализме жизненных явлений мы находим оправдание любому неприятному для нас событию и это дает нам силу для того, чтобы жить дальше.

В силу своей потребности знать, мы пытаемся получить ответы на вопросы: «Как появился Человек? В чем смысл человеческого существования?» Дверь, за которой находится картина сотворения мира, для нас всегда будет закрыта. И чтобы ни говорили по этому поводу научные и религиозные деятели, всего лишь это догадки, не более. Но не стоит затрагивать эту часть познания. Не дано, значит, не дано. Но кто запретит нам порассуждать о том, о чем говорят теперь на всех уровнях человеческого общения, в силу его научного и даже несколько эзотерического ореола. Об искусственном интеллекте – детища естественного разума.

Задумаемся: А так ли случайно появление искусственного интеллекта?

Человек, став разумным, придумывал технические усовершенствования, дабы облегчить свой труд. Недаром «техника» считается «мускулами» человека. Слияние науки и техники ознаменовало появление технологий. Процесс научного и технического развития шел постепенно. Менялись поколения, каждое из которых, освоив новые технологии, как «эстафетную палочку», передавала знания следующему, оставив определенный задел «незнания». «И вот появится новое поколение, умственное превосходство которого будет сказываться уже с первых дней жизни. И эти новые умницы, представители вида Homo Sapiientissimus (человек разумнейший), конечно же, не остановятся на достигнутом. Они ринутся к бесконечности совершенства, а мы останемся у подножья их восхождения» [1]

Что мы видим сегодня? Появление детей индиго говорит нам о том, что они являются представителями этого нового поколения, в котором искусственный интеллект станет неотъемлемой частью жизни людей.

Живя в обстановке высоких технологий, человек направляет свою мысль на себя, как объект, способный мыслить и выполнять заданные действия. Он создает искусственный интеллект, беря за основу систему деятельности нейронных связей человеческого мозга.

В мозге человека «каждый нейрон неподвижно закреплен на своем месте. Импульсы по нейрону бегут только в одну сторону от периферии к центру или от центра к периферии. То как будут работать нейроны, с какой частотой и силой будут идти его импульсы зависит от работы миллионов и миллионов других нейронов» [1]. «Нейроны взаимодействуют между собой посредством коротких серий импульсов продолжительностью несколько микросекунд. Частота импульсов составляет от нескольких единиц до сотен герц, что в миллионы раз медленнее, чем в электронных схемах» [2]. Именно этот факт натолкнул ученых–математиков, используя возможности компьютеров, разработать модель математического нейрона, чем ознаменовали начало создания искусственного интеллекта.

Любой научный и технологический прорыв, как правило, имеет на своем пути препятствия. Иногда эти препятствия создают коллеги-ученые, предлагая свое видение проблемы, но всегда, таким препятствием будет оставаться человеческий консерватизм (человеку легче живется с тем, к чему он уже привык). Консервативные качества обычно присущи пожилым людям. Вы обращали внимание, как легко справляется с гаджетами молодежь? Молодежь быстро отзывается на все новое, быстро усваивает и быстро внедряет. Вот почему в выполнении интеллектуальных работ предпочтительна молодежь. И в этом мы также видим подтверждение закономерности смены поколений.

Препятствием дальнейших разработок и использования искусственного интеллекта может быть недоверие части общества к возможностям и последствиям внедрения искусственного интеллекта, которое можно сформулировать следующим образом.

– недоверие к результатам, полученным методами искусственного интеллекта в силу предполагаемых ошибок программиста;

- возможный недостаточный уровень компетентности преподавателей в обучении программистов искусственного интеллекта;
- высвобождение персонала работающих в связи их заменой искусственным интеллектом;
- появление в связи с этим «лишних людей»;
- отсутствие законодательных решений по выдаче социальных пособий «лишним людям»;
- появление людей, вынужденный «отдых» которых, в конечном счете, может сделать их «отбросами общества».

Но применение искусственного интеллекта имеет своих сторонников в силу причин, которые общество игнорировать не может.

Первая, на первый взгляд совсем незначительная причина: Искусственный интеллект не имеет эмоций, а потому не подвержен эмоциональным срывам, симпатиям и антипатиям, косвенному напору со стороны заинтересованных лиц, настроению, состоянию здоровья и еще многому другому, чему подвержен человек при принятии какого-либо решения, и которое называют сегодня «человеческим фактором». В силу перечисленных аргументов в пользу искусственного интеллекта, его можно использовать не только на производстве, в социальной сфере, в здравоохранении, в банковском деле и т.д., но и на уровне принятия правительственных решений. И, наконец, искусственный интеллект необходим там, где возникают трудности для человека в поле его деятельности.

Какова перспектива использования искусственного интеллекта? Стоит ли считать, что появление искусственного интеллекта является производным появления Homo Sapiientissimus (человека разумнейшего)?

«Нет, мир...видится не таким, каким рисуют будущее некоторые ревнители кибернетики. Они видят главную линию будущего прогресса в неограниченном машинном «продолжении» человеческого мозга. Естественный разум, родитель, все более жалкий по сравнению со своим искусственным продолжением, продолжает, покуда возможно на дитяти. Но наступает момент, когда взывавшее благородство (или страх перед бунтом) заставляет его признать общественное равноправие человека и машины. Потом сдаться на милость машины... и исчезнуть. Да и зачем тогда нужен будет человек? Пройденный этап. Эстафету эволюции разума примут машины» [1]

Печальная картина. Но если подумать, то, действительно, искусственный интеллект вместе с преимуществами своего использования приведет к деградации части «ненужных», выкинутых с производства людей, а значит и общества в целом.

Так нужно ли останавливаться и отказываться от дальнейших разработок и использования искусственного интеллекта?

Однозначно – нет.

Во-первых, мы не можем и не должны оградить себя от мирового пространства, в котором искусственный интеллект набирает силу.

Во-вторых, процесс научно–технического и технологического движения, в котором искусственный интеллект захватывает лидирующие позиции, остановить нельзя.

В-третьих, освоив возможности применения искусственного интеллекта и почувствовав все его преимущества, вряд ли мы сможем отказаться от его услуг.

И, наконец, все рассуждения о плюсах и минусах искусственного интеллекта не имеют смысла, поскольку его появление также неотвратимо, как все, что нас окружает.

Впрочем, это взгляд дилетанта, называющего себя «интеллектуальным обывателем», а потому возможно, далекого от Истины.

Библиографический список

1. Леви В. Охота за мыслью. – М.: Молодая гвардия, 1967.
2. Ясницкий Л.Н., Данилевич Т.В. Современные проблемы науки. –М.: БИНОМ, 2008.

ARTIFICIAL INTELLIGENCE THROUGH THE EYES OF AN INTELLIGENT LAYMAN

Danilevich Tatyana Vasilyevna

Perm state University of Humanities and education
24 Sibirskaya str., Perm, 614990, yasn@psu.ru

The article raises and discusses the place of artificial intelligence in our lives, the relationship of man with artificial intelligence, and discusses its future development. The presentation is conducted as a "view from the outside" of the layman.

Key words: artificial intelligence, Homo Sapientissimus, intelligence, evolution, progress.

ОПРЕДЕЛЕНИЕ УРОВНЯ ДЕМОКРАТИИ В СТРАНАХ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

Пухов Николай Александрович

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15,
dariusjohnson555@gmail.com

В статье представлено описание разработки нейросетевой модели, позволяющей определить уровень демократии в странах. Был проведен ряд исследований с использованием полученной модели, результаты которых приведены в данной статье.

Ключевые слова: искусственный интеллект, нейронная сеть, закономерности, моделирование, демократия, политика.

Введение. В современном мире увеличивается спрос общества на демократические ценности. Демократия, или как её ещё называют, народовластие, – это политический режим, при котором народ или его большинство служит источником и носителем политической, государственной власти [6].

В школьных учебниках истории и обществознания выделяют несколько характерных признаков, присущих странам с демократическим режимом:

- Свободные выборы
- Наличие независимых средств массовой информации
- Широкие и гарантированные права и свободы граждан

Целью настоящей работы является создание нейросетевой модели, которая позволяет по набору параметров, кратко характеризующих то или иное государство, определить степень народовластия в нём в числовом выражении и даёт возможность сказать, к какому политическому режиму это государство относится. Построенная модель также позволит узнать, какие параметры в большей степени влияют на существование демократических ценностей в стране и что нужно предпринять для подъёма уровня народовластия.

Нейронная сеть имеет 15 входных параметров, которые описаны в таблице 1.

Таблица 4 – Описание входных данных

Вход	Описание
------	----------

X1	Индекс восприятия коррупции
X2	Индекс свободы СМИ
X3	Уровень счастья граждан
X4	Продолжительность жизни
X5	Уровень урбанизации
X6	Индекс учета мнения народа правительством
X7	Уровень отсутствия насилия в стране
X8	Эффективность работы правительства
X9	Степень качества законодательства
X10	Уровень миролюбия
X11	Уровень свободы граждан
X12	Уровень стабильности
X13	Уровень терроризма
X14	ВВП на душу населения
X15	Уровень экономической свободы

Выходной параметр один – это уровень демократии в стране.

Нейросеть создана и обучена с помощью программного обеспечения «Нейросимулятор 5.0» [1].

Данные для обучения были взяты из открытого источника «Гуманитарный портал» [5] и преобразованы специальной программой в требуемый нейросимулятором формат. В результате, для обучающего множества было использовано 102 примера, а для тестового множества – 22 примеров (20% от обучающего множества).

Использование следствия из теоремы Арнольда-Колмогорова (формула 2.1) [2] дало возможность найти оптимальное количество нейронов на скрытом слое.

$$\frac{N_y Q}{1 + \log_2 Q} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) \quad (2.1)$$

В этой формуле: N_y – количество выходных нейронов, N_x – количество входных ней, Q – количество примеров в обучающем множестве, N_w – необходимое число синоптических связей. Полученная оценка: $34 \leq N_w \leq 156,75$.

Оценка количества входных нейронов N : $1 \leq N \leq 7$. Были изучены различные конфигурации скрытого слоя и установлено оптимальное количество нейронов. Результаты исследования представлены на рисунке 1.



Рисунок 1. Результаты поиска оптимального количества нейронов

Таким образом, оптимальным решением является использование в структуре нейросети 2-х нейронов. Наиболее удачным вариантом функции активации оказалась линейная функция. При этом среднеквадратичная относительная ошибка тестового множества при обучении составила 8,6%.

Погрешность результатов, полученных в ходе работы нейросети, представлена на рисунке 3.




Рисунок 2. Сравнение реальных и вычисленных значений

Полученная нейронная сеть успешно справилась с вычислением уровня народовластия в странах, которые являлись примерами из тестового множества. Это говорит о том, что данную сеть можно использовать для получения практической информации.

Существует несколько способов определения важности входных параметров. Один из способов – это поочередное исключение входных параметров и дальнейшее наблюдение за изменениями погрешности. В нашем случае была использована встроенная в нейросимулятор функция

измерения степени важности входных параметров [1]. Результаты её работы представлены на рисунке 4.




Рисунок 3. Значимость параметров полученной нейросети

Можно наблюдать интересную картину: оказывается, что свобода СМИ не влияет на уровень демократии в стране. Однако считается, что данный фактор является одним из важных. Коррупция, следуя из полученной диаграммы, тоже не оказывает существенного влияния. При этом нейросеть показала, что качество законодательства является одним из важных критериев в определении народовластия в государстве.

Таким образом, имеется вся необходимая информация для проведения экспериментов с помощью данной нейросети.

Используя полученные данные, легко установить, что на уровень демократии главным образом влияют следующие факторы: качество законодательства, миролюбие и учет мнения народа.

Рассмотрим страны: Россию (таблица 2) и Беларусь (таблица 3).

Таблица 2 – Информация о России

Описание	Значение
Индекс восприятия коррупции	29
Свобода СМИ	44%
Уровень счастья граждан	34
Продолжительность жизни	72
Урбанизация	74
Учет мнения народа	29%
Отсутствие насилия в стране	22%

Эффективность работы правительства	43%
Качество законодательства	32%
Миролюбие	2,5
Свобода граждан	22
Стабильность	81%
Терроризм	4,9
ВВП на душу населения	10
Экономическая свобода	58
Уровень демократии	3,8

Таблица 3. Информация о Беларуси

Описание	Значение
Индекс восприятия коррупции	32
Свобода СМИ	47%
Уровень счастья граждан	37
Продолжительность жизни	74
Урбанизация	78
Учет мнения народа	30%
Отсутствие насилия в стране	46%
Эффективность работы правительства	17%
Качество законодательства	31%
Миролюбие	1,9
Свобода граждан	17
Стабильность	73%
Терроризм	0
ВВП на душу населения	5,67
Экономическая свобода	57
Уровень демократии	3,0

Рассмотрим влияние качества законодательства (%) на уровень народолюбия в этих странах.




Рисунок 4. Влияние качества законодательства на уровень демократии

Графики, представленные на рисунке 4, идут сначала вверх, однако для России график, начиная с 60% и далее, идёт на спад. Отсутствие роста объясняется тем, что в условиях РФ качество законодательства не гарантирует его исполнения, а небольшой спад можно объяснить погрешностью нейросетевой модели. При этом для республики Беларусь качество законодательства достаточно сильно влияет на уровень народовластия и это верно: в конституции Беларуси нет ограничения на кол-во президентских сроков, что является грубым нарушением принципов демократического государства.

Рассмотрим теперь влияние степени миролюбия на уровень демократии в России и Беларуси.




Рисунок 5. Влияние миролюбия на уровень демократии

Результат, представленный на рисунке 5, вполне объясним. Поддержание демократии в стране тесно сопряжено с постоянными требованиями народа на достойный уровень жизни и учет их мнения в разных вопросах. Задача правительства – удовлетворять требования народа. Однако, чем миролюбивее народ, тем меньше в стране протестная активность в ответ на разные несправедливые решения правительства. Это влечет за собой произвол во властных структурах и отсутствие намерения со стороны правительства удовлетворять требования, выдвинутые народом, по разным вопросам, что является нарушением демократии.

Наконец, изучим влияние такого параметра, как “индекс учёта мнения народа”.




Рисунок 6. Влияние параметра “индекс учёта мнения народа” на уровень демократии

Результат, представленный на рисунке 6, поддается объяснению. Действительно, ни одно демократическое государство немислимо без учёта правительством мнения народа при решении важных государственных вопросов.

Заключение. Была успешно реализована математическая модель на основе технологий нейросетевого моделирования, которая позволила выявить параметры, существенные с точки зрения влияния на уровень демократии, и которая может определить принадлежность государства к тому или иному политическому режиму. На примере таких стран как Россия и Беларусь были получены определенные знания в виде графиков, которые могут быть использованы правительством или активными гражданами в реальной жизни для создания более демократического государства.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0 // Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
2. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007. – 271 с.
3. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. – 221с.
4. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5. – С. 48-56.
5. Гуманитарный портал. URL: <https://gtmarket.ru> (Дата обращения 24.06.2020)
6. Википедия. Демократия. URL: <https://ru.wikipedia.org/wiki/Демократия> (Дата обращения 24.06.2020)

DETERMINING THE LEVEL OF DEMOCRACY IN COUNTRIES USING NEURAL NETWORK MODELING

Pukhov Nikolay Alexandrovich

Perm State National Research University,

PMI. 614990, Russia, Perm, ul. Bukireva, 15, dariusjohnson555@gmail.com

The article describes the development of a neural network model that allows you to determine the level of democracy in countries. A number of studies of the resulting model were carried out, the results of which are given in this article.

Key words: artificial intelligence, neural network, patterns, modeling, democracy, politics.

СТАТИЧЕСКОЕ ИНТЕРПОЛЯЦИОННОЕ ПРОГНОЗИРОВАНИЕ ПОКАЗАТЕЛЕЙ РЫНКА НЕДВИЖИМОСТИ С ИСПОЛЬЗОВАНИЕМ ДИСКРЕТНОЙ ПРОСТРАНСТВЕННО-ПАРАМЕТРИЧЕСКОЙ МОДЕЛИ (ДППМ)

Стерник Сергей Геннадьевич

Финансовый университет при Правительстве РФ,
125993, Москва, Ленинградский проспект, д.49, sergey-sternik@yandex.ru

В статье представлено описание применения методологии дискретного пространственно-параметрического моделирования рынка недвижимости (ДППМ) для мониторинга рынка, для построения динамических индексов рынка и для массовой оценки объектов недвижимости. Методология основана на статистическом кластерном анализе и позволяет также осуществлять статическое интерполяционное пространственно-параметрическое прогнозирование значений индикаторов рынка в малых кластерах с недостаточным объемом выборки и на узких рынках с малым или отсутствующим объемом предложения.

Ключевые слова: рынок недвижимости, кластерный анализ, мониторинг, моделирование, прогнозирование, массовая оценка, динамические индексы, малые выборки

Введение. Методология дискретного пространственно-параметрического моделирования рынка недвижимости (ДППМ) первоначально была разработана и использовалась как средство анализа сегмента рынка [1, 2, 3]. В том числе важнейшей задачей стало применение указанной методологии в определении средних рыночных показателей, пригодных для построения системы индексов рынка недвижимости [6]. Затем область ее применения была расширена на задачу массовой оценки объектов [4 – 10]. В работах [11, 12] произведено расширение возможностей применения ДППМ на статическое интерполяционное пространственно-параметрическое прогнозирование значений индикаторов рынка в малых кластерах с недостаточным объемом выборки и на узких рынках с малым или отсутствующим объемом предложения. Одновременно решалась задача углубления формализации процедуры построения ДППМ. Интегрированные результаты данных работ публикуются в настоящей статье.

Сущность методологии. ДППМ – это упорядоченный набор показателей (индикаторов) состояния сегмента рынка, полученный в результате параллельно-последовательного сечения рассматриваемой выборки объектов недвижимости по различным признакам на дискретные подвыборки (кластеры).

Расчленение общей выборки на кластеры повышает однородность выборок в кластерах и уменьшает диапазон разброса цен, а при достаточном объеме выборок – снижает дисперсию, среднееквадратическое (стандартное) отклонение и погрешность в определении среднего значения.

Наиболее важными ценообразующими признаками являются: местоположение (территориальная локация), качество (категория функционального назначения, морфотип, класс качества), размер (диапазон общей площади, либо количество комнат в квартире для жилья).

Каждый их признаков может иметь не один, а два-три уровня сечения.

Так, в простейшем случае анализа рынка города в качестве признака местоположения используется зона, которая может представлять собой район в административных границах либо неформальный район, в границах которого средняя удельная цена статистически значимо отличается от смежных районов, а погрешность минимальна. Например, для анализа рынка недвижимости Москвы чаще всего используются 12 зон в виде административных округов (ЦАО, ЗАО, СЗАО, САО, СВАО, ВАО, ЮВАО, ЮАО, ЮЗАО, ЗелАО, ТиНАО) или 137 муниципальных районов. В отдельных задачах выделяются АО на первом уровне и муниципальные районы на втором. Наконец, выделяют три-четыре «пояса» по удалению от Центра (в пределах Садового кольца, Третьего транспортного кольца, МКАД плюс «Замкадье» – ТИНАО, ЗелАО и районы вне МКАД), которые потом еще раз расчленяются на районы, находящиеся на этих поясах.

В более сложном случае анализа рынка региона поступают аналогично последнему варианту анализа мегаполиса. Так, территорию Московской области расчленяют на 4-8 секторов (Запад, Север, Восток, Юг или плюс Северо-Запад, Северо-Восток, Юго-Восток, Юго-Запад) и 3-4 пояса (Ближнее Подмосковье до Малого кольца, Среднее Подмосковье до Большого кольца, Дальнее Подмосковье до границ области. Затем на втором уровне каждый образовавшийся сегмент территории расчленяется на входящие в него муниципальные районы, на третьем – выделяются города (населенные пункты).

Наконец, в случае анализа рынка РФ выделяются на первом уровне Федеральные округа, на втором – регионы, на третьем – города регионов.

В качестве признака качества объектов в простейшем случае анализа жилищного рынка города (рынок квартир в многоквартирных домах) используется показатель морфотипа (например, панельные, кирпичные, монолитные, монолитно-каркасные дома) либо класса качества: эконом-класс, комфорт-класс, бизнес-класс, элитный класс, либо два укрупненных класса – массовый и престижный (повышенной комфортности). Аналогично, при анализе рынка офисной недвижимости расчленение идет по классам качества А, В, С и т.д.

В более сложном случае анализа рынка жилой недвижимости, состоящего из сегментов многоквартирных многоэтажных жилых домов, малоэтажных домов, индивидуальных и сблокированных домов на первом уровне идет расчленение по сегментам, на втором – по классам качества.

Аналогично, при анализе рынка коммерческой недвижимости, состоящего из нескольких сегментов (офисная, торговая, складская недвижимость и т. п.), на первом уровне рынок расчленяется по видам функционального назначения, на втором – по классам качества или морфотипам.

В качестве признака размера используется либо количество комнат в квартире (для вторичного рынка жилой недвижимости), либо 3-5 диапазонов общей площади помещений (для первичного рынка жилой недвижимости, рынка коттеджей, офисных помещений), либо несколько диапазонов площади земельных участков.

Наряду с приведенными тремя признаками, желательно строить ДППМ с использованием и других ценообразующих признаков. Например, этажность зданий (особенно при анализе рынка незавершенного строительства), расположение квартир на крайних или средних этажах, наличие и качество ремонта (для вторичного рынка жилой недвижимости), наличие и качество отделки (для первичного рынка), категория земель и вид разрешенного использования (для рынка земельных участков).

Рассмотрим основные структурные элементы ДППМ.

Показатель (индикатор) – статистическая величина, агрегирующая данные в выборке (минимальная, максимальная и средневзвешенная удельная цена (ставка аренды), объем строительства, объем предложения объектов и т.д.).

Признак сечения – фактор, влияющий на уровень показателей (индикаторов) рынка, по которому произведено сечение данных.

Ячейка – место размещения единицы информации (значение на пересечении строки признаков и столбца показателей).

Кластер – строка ДППМ определенного уровня сечения.

Уровень сечения – набор кластеров, образовавшийся вследствие очередного шага параллельно-последовательно сечения исходной выборки данных.

Конечный кластер (ядро) – строка ячеек, содержащих показатели неделимой выборки.

Слой ячеек – набор (столбец) ячеек по одному показателю.

Построение ДППМ происходит в три этапа.

1) Строится *исходная* ДППМ, в которой зафиксированы все признаки сечения и все показатели, но ячейки не заполнены.

2) В модель вводятся показатели объема выборок и исключаются ячейки (строки) с нулевыми и сверхмалыми (до 3-5 элементов) объемами выборок – возникает т.н. *предварительная* ДППМ.

3) Аналитик производит расчет всех показателей, проверку значимости различия средних в смежных выборках, объединение выборок с незначимыми различиями либо дополнительное сечение путем корректировки диапазонов признаков с целью минимизации погрешности до уровня не более 10-15%, исключение строк с большей погрешностью. В результате образуется *оптимизированная* ДППМ.

В модернизированной для узких рынков методике работа аналитика корректируется: исключается п. 2), в п. 3) не исключаются строки с большой погрешностью. В эти ячейки заносятся результаты интерполяционного прогнозирования показателей.

Форма ДППМ при трех признаках дифференциации и трех классификаторах в каждом признаке приведена в табл. 1.

Таблица 1 – Форма ДППМ при трех признаках дифференциации, трех классификаторах в каждом признаке и четырех показателях

Уровень расчленения	№ кластера	Признаки			Показатели			
		1	2	3	1	2	3	4
0	0	По всем признакам M0, K0, P0						
1	1	M1	K0	P0				
1	2	M2	K0	P0				
1	3	M3	K0	P0				
1	4	M0	KA	P0				
1	5	M0	KB	P0				
1	6	M0	KB	P0				
1	7	M0	K0	Pa				
1	8	M0	K0	Pб				
1	9	M0	K0	Pв				
2	10	M1	KA	P0				
2	11	M1	KB	P0				
2	12	M1	KB	P0				
2	13	M1	K0	Pa				
2	14	M1	K0	Pб				
2	15	M1	K0	Pв				
2	16	M2	KA	P0				
2	17	M2	KB	P0				
2	18	M2	KB	P0				
2	19	M2	K0	Pa				
2	20	M2	K0	Pб				
2	21	M2	K0	Pв				
2	22	M3	KA	P0				
2	23	M3	KB	P0				
2	24	M3	KB	P0				
2	25	M3	K0	Pa				
2	26	M3	K0	Pб				
2	27	M3	K0	Pв				
3	28	M1	KA	Pa				
3	29	M1	KB	Pa				
3	30	M1	KB	Pa				
3	31	M1	KA	Pб				
3	32	M1	KB	Pб				
3	33	M1	KB	Pб				
3	34	M1	KA	Pв				
3	35	M1	KB	Pв				
3	36	M1	KB	Pв				
3	37	M2	KA	Pa				
3	38	M2	KB	Pa				
3	39	M2	KB	Pa				
3	40	M2	KA	Pб				
3	41	M2	KB	Pб				

3	42	M2	KB	P6				
3	43	M2	KA	Pв				
3	44	M2	KB	Pв				
3	45	M2	KB	Pв				
3	46	M3	KA	Pa				
3	47	M3	KB	Pa				
3	48	M3	KB	Pa				
3	49	M3	KA	P6				
3	50	M3	KB	P6				
3	51	M3	KB	P6				
3	52	M3	KA	Pв				
3	53	M3	KB	Pв				
3	54	M3	KB	Pв				

Примечание: На уровне 0 – один кластер, на уровне 1 – 9 кластеров, на уровне 2 – 18 кластеров, на уровне 3 – 27 кластеров.

Обозначения: M1-M3 – зоны местоположения, KA-KB – классы качества, Pa-Pв – диапазоны размеров.

Пример ДППМ рынка аренды офисных помещений в Москве (при двух признаках дифференциации) приведен в табл. 2.

Таблица 2 – Пример ДППМ рынка аренды офисных помещений в Москве с дифференциацией по двум признакам

Зона	клас с	объем предложения			ставка аренды, \$/кв. м в год				СКО	погрешност ь		К-т вариан ции, %
		шт.	млн. \$	тыс. кв. м	срвзв. по пло щади	макс.	мин.	ср. ариф м.		\$/кв. м в год	%	
Всего по Москве	Все	8477	1147,9	2654,4	432	1500	100	396	160,7	3,49	0,81	37,15
	A	211	194,4	275,2	706	1500	350	721	188,0	25,95	3,67	26,63
	B	1066	323,0	659,1	490	1441	100	494	176,6	10,82	2,21	36,03
	C	5325	531,3	1431,8	371	1500	100	376	138,8	3,81	1,03	37,41
	D	242	19,0	78,6	242	480	100	219	92,0	11,85	4,89	37,97
ЦАО	все	2487	483,4	822,0	588	1500	120	519	187,2	7,51	1,28	31,83
	A	184	165,3	223,0	741	1500	350	726	191,2	28,27	3,81	25,79
	B	531	137,4	235,5	584	1441	120	551	189,4	16,45	2,82	32,45
	C	1294	149,8	295,7	507	1500	150	501	173,7	9,66	1,91	34,29
	D	35	3,3	10,3	319	450	121	287	106,4	36,51	11,45	33,37
3АО	все	452	79,2	186,1	426	1200	12	389	151,3	14,25	3,35	35,52
	A	18	24,9	45,9	543	1000	48	707	168,8	81,89	15,07	31,06
	B	29	5,8	14,3	404	1200	12	403	274,5	103,7	25,70	67,99
	C	258	36,8	97,6	376	1077	15	361	110,9	13,83	3,67	29,45
	D	9	1,2	3,9	314	400	12	254	108,4	76,66	24,39	34,49

Зона	класс	объем предложения			ставка аренды, \$/кв. м в год				СКО	погрешность		К-т вариации, %
		шт.	млн. \$	тыс. кв. м	срвзв. по площади	макс.	мин.	ср. ариф. м.		\$ / кв. м в год	%	
	Е	138	10,6	24,4	433	1000	200	405	128,0	21,87	5,05	29,53
СЗАО	все	330	34,70	108,8	319	900	101	345	109,5	12,08	3,79	34,35
	А	0	-	-	-	-	-	-	-	-	-	-
	В	32	6,2	17,7	352	900	200	371	131,9	47,39	13,48	37,52
	С	205	25,9	83,4	311	900	120	345	111,4	15,59	5,01	35,80
	Д	7	0,1	0,7	193	300	121	228	80,1	65,36	33,83	41,43
	Е	86	2,4	7,0	343	750	101	345	92,2	20,00	5,84	26,91
САО	все	1068	124,7	353,7	353	815	121	344	101,2	6,20	1,76	28,71
	А	0	-	-	-	-	-	-	-	-	-	-
	В	85	30,2	68,8	439	815	150	438	138,7	30,28	6,89	31,60
	С	756	81,2	240,7	337	800	140	335	77,4	5,64	1,67	22,97
	Д	31	4,3	18,3	232	450	121	228	94,0	34,32	14,78	40,48
	Е	196	9,1	25,9	351	800	141	358	129,0	18,48	5,27	36,79
СВАО	все	808	102,1	295,6	345	1080	108	337	97,8	6,89	1,99	28,33
	А	0	-	-	-	-	-	-	-	-	-	-
	В	62	23,3	58,1	402	1080	110	413	131,8	33,76	8,41	32,83
	С	591	72,2	215,7	335	800	108	338	78,3	6,45	1,93	23,39
	Д	36	1,4	6,1	236	353	110	190	73,2	24,75	10,49	31,02
	Е	119	5,1	15,8	324	750	120	334	120,7	22,23	6,86	37,26
ВАО	все	995	63,14	188,5	335	747	100	328	87,8	5,57	1,66	26,21
	А	0	-	-	-	-	-	-	-	-	-	-
	В	37	9,8	22,2	442	747	100	430	179,9	59,96	13,56	40,69
	С	741	44,6	132,3	337	706	144	334	70,6	5,19	1,54	20,94
	Д	20	1,7	11,2	155	350	120	203	70,7	32,44	20,95	45,66
	Е	195	6,7	22,1	302	714	121	301	97,1	13,9	4,61	32,12

Зона	класс	объем предложения			ставка аренды, \$/кв. м в год				СКО	погрешность		К-т вариации, %
		шт.	млн. \$	тыс. кв. м	срвзв. по площади	макс.	мин.	ср. ариф. м.		\$ / кв. м в год	%	
							0			5		
ЮВА О	все	992	62,97	203,7	309	720	10 0	301	95,4	6,06	1,96	30,86
	A	0	-	-	-	-	-	-	-	-	-	-
	B	59	12,0	27,1	443	700	12 0	412	114,8	30,16	6,81	25,92
	C	660	40,4	137,1	294	720	10 0	296	76,9	5,99	2,04	26,13
	D	66	2,6	12,7	204	400	12 0	192	69,9	17,33	8,49	34,22
	E	207	8,0	26,8	299	706	10 0	320	108,6	15,13	5,07	36,36
ЮАО	все	963	135,1	337,6	400	850	12 0	379	131,8	8,50	2,12	32,93
	A	5	1,9	2,5	753	850	69 0	756	69,9	69,86	9,28	9,28
	B	182	74,5	160,8	463	780	12 0	473	108,5	16,13	3,48	23,43
	C	620	50,5	147,9	341	822	12 0	362	125,1	10,06	2,95	36,66
	D	28	3,7	12,7	292	480	12 1	231	99,1	38,15	13,07	33,96
	E	128	4,5	13,7	331	850	18 0	348	103,4	18,34	5,54	31,20
ЮЗА О	все	291	39,63	90,64	437	750	10 0	401	132,6	15,57	3,56	30,33
	A	0	-	-	-	-	-	-	-	-	-	-
	B	26	10,5	21,3	494	750	22 0	468	180,0	72,00	14,56	36,41
	C	136	20,6	48,3	426	750	15 0	407	140,4	24,17	5,67	32,92
	D	6	0,5	1,5	313	420	10 0	250	134,5	120,2	38,42	42,95
	E	121	6,1	16,4	374	700	19 0	385	99,8	18,22	4,87	26,68

Метод параллельно-последовательных сечений. При использовании статистического кластерного анализа для расчета среднерыночной удельной цены (ставки аренды) объектов-аналогов в конечном кластере, в соответствии с методологией дискретного пространственно-параметрического моделирования рынка недвижимости (ДППМ), сначала исходная выборка рассеивается по первому пенообразующему фактору (например – по местоположению). Пусть i – порядковый номер исследуемой

территориальной зоны объекта, характеризуемой средней удельной ценой (ставкой аренды) в кластере \bar{C}_i .

Затем исходная выборка рассекается по второму ценообразующему фактору (например – по классу качества). Пусть j – порядковый номер исследуемого класса качества объекта, характеризуемой средней удельной ценой (ставкой аренды) в кластере \bar{C}_j .

Затем исходная выборка рассекается по третьему ценообразующему фактору (например – по диапазону размеров). Пусть k – порядковый номер исследуемого диапазона размеров объекта, характеризуемой средней удельной ценой (ставкой аренды) в кластере \bar{C}_k .

Так образуется первый уровень кластеров. При трех признаках сечения и трех классификаторах в каждом признаке количество кластеров равно 9.

Затем каждая из полученных подвыборок (кластеров) рассекается по второму или третьему ценообразующему фактору. Например, подвыборки кластеров первого уровня, выделенных по признаку местоположения, рассекаются по признаку класса качества. Образуются кластеры второго уровня сечения, которые характеризуются средней удельной ценой (ставкой аренды) \bar{C}_{ij} .

Аналогично подвыборки кластеров, выделенных по признаку местоположения, рассекаются по признаку размера (диапазона площади) объекта. Образуются кластеры второго уровня сечения, которые характеризуются средней удельной ценой (ставкой аренды) \bar{C}_{ik} .

Наконец, кластеры первого уровня, выделенные по признаку класса качества, расчленяются по признаку размера. Образуются кластеры второго уровня сечения, которые характеризуются средней удельной ценой (ставкой аренды)

\bar{C}_{kj} .

Всего на втором уровне при трех признаках сечения и трех классификаторах в каждом признаке образуется 18 кластеров.

Подвыборки второго уровня, в свою очередь, рассекаются по третьему фактору. Например, кластеры, выделенные по признаку местоположение-качество, рассекаются по диапазону размеров, выделенные по признаку местоположение-размер – по признаку качества. Образуются кластеры третьего уровня, характеризующиеся средней удельной ценой (ставкой аренды) \bar{C}_{ijk} . В заданных условиях примера таких кластеров образуется 27.

Далее по целесообразности и технической возможности может происходить еще ряд сечений подвыборок по различным факторам. Например, четвертым фактором сечения для рынка аренды офисных помещений может быть наличие/отсутствие отделки, пятым – срок аренды, и т.д.

В результате каждого этапа (цикла) сечений образуются уменьшающиеся по мощности (количеству элементов) подвыборки. Но каждая из последующих подвыборок более однородна с точки зрения входящих в нее объектов, чем предыдущие. Степень однородности подвыборки можно оценивать по величине размаха вариации величин, т.е. разности $C_{max} - C_{min}$, или

коэффициента вариации v , равного отношению среднеквадратичного отклонения (СКО, S) к средней \bar{C} в данном кластере. Соответственно, от однородности подвыборки в кластере и от числа объектов в подвыборке будет зависеть погрешность в определении средней величины (математического ожидания) данной подвыборки δ .

В идеальном случае в результате последнего сечения образуется подвыборка, состоящая из нескольких объектов-аналогов, обладающих схожими ценообразующими признаками (конечный кластер), с близкими к нулю коэффициентом вариации и погрешностью.

Среднее значение удельной цены (арендной ставки) этого последнего подмножества объектов (математическое ожидание) формально является среднерыночной удельной ценой (арендной ставкой) объектов-аналогов в конечном кластере.

Методика статического интерполяционного пространственно-параметрического прогнозирования средней удельной цены (ставки аренды) в нерепрезентативных кластерах. Если при параллельно-последовательном сечении выборки по трем факторам (местоположение – качество – размер) погрешность δ_{ijk} в определении средней \bar{C}_{ijk} в конечном кластере меньше или равна принятой допустимой величины (10-15%), то сечение завершено, и статистический результат принимается как искомая расчетная удельная цена (ставка аренды) оцениваемого объекта

$$C = \bar{C}_{ijk}.$$

Нетрудно показать, что от последовательности сечения единой исходной выборки значение и погрешность средней в конечном кластере не меняются:

$$C = \bar{C}_{ijk} = \bar{C}_{ikj} = \bar{C}_{jik} = \bar{C}_{jki} = \bar{C}_{kij} = \bar{C}_{kji} = \bar{C}_{ijk}.$$

Все средние в кластерах рассчитываются как средневзвешенные по площади. Так, в первом сечении для территориального кластера

$$\bar{C}_i = \text{Ср.взв.место} = \frac{\sum(C_i \times S_i)}{\sum S_i},$$

где S_i – площадь каждого помещения в i -й выборке.

Соответственно, для конечного сечения и, собственно, для оцениваемого объекта

$$C = \bar{C}_{ijk} = \text{Ср.взв.класт.} = \frac{\sum(C_{ijk} \times S_{ijk})}{\sum S_{ijk}}.$$

Если погрешность в определении средней в кластере третьего уровня сечения больше допустимой (выборка нерепрезентативна), или объекты-аналоги в кластере вообще отсутствуют, а в кластере второго уровня сечения погрешность меньше или равна допустимой, то расчет удельной цены (ставки аренды) осуществляется путем применения коэффициентов ценовых поправок второго уровня к среднему значению подвыборки второго уровня:

$$C = \bar{C}_{jk} \times K2_{\text{место}}, \text{ ИЛИ}$$

$$C = \bar{C}_{ij} \times K2_{\text{качество}}, \text{ ИЛИ}$$

$$C = \bar{c}_{ki} \times K2_{\text{размер}}$$

Применение любой из формул дает один и тот же результат, а выбор одной из них определяется наличием данных верхнего уровня.

Если погрешность в определении средней в кластере второго уровня сечения больше допустимой, или объекты-аналоги в кластере вообще отсутствуют, а в кластере первого уровня сечения погрешность меньше или равна допустимой, то расчет удельной цены (ставки аренды) осуществляется путем применения коэффициентов ценовых поправок первого уровня к среднему значению подвыборки первого уровня:

$$C = \bar{c}_i \times K1_{\text{размер}} \times K1_{\text{качество}}, \text{ или}$$

$$C = \bar{c}_j \times K1_{\text{место}} \times K1_{\text{качество}}, \text{ или}$$

$$C = \bar{c}_k \times K1_{\text{место}} \times K1_{\text{размер}}.$$

Для каждого из кластеров третьего уровня, в котором выборка отсутствует либо нерепрезентативна, ценовая поправка по каждому фактору определяется как отношение среднего значения удельной цены (ставки аренды) в интересующей подвыборке второго уровня сечения к среднему значению в выборке первого уровня сечения:

$$K2_{\text{место}} = \frac{\bar{c}_{ij}}{\bar{c}_j}, \text{ или } K2_{\text{место}} = \frac{\bar{c}_{ik}}{\bar{c}_k},$$

где $K2_{\text{место}}$ – коэффициент местоположения, ij и ik – индексы кластеров исследуемой территориальной зоны, с дифференцированием, соответственно, по размеру или по качеству;

$$K2_{\text{размер}} = \frac{\bar{c}_{ji}}{\bar{c}_i}, \text{ или } K2_{\text{размер}} = \frac{\bar{c}_{jk}}{\bar{c}_k},$$

где $K2_{\text{размер}}$ – коэффициент размера, ji и jk – индексы кластеров исследуемого диапазона площадей, с дифференцированием, соответственно, по местоположению или по качеству;

$$K2_{\text{качество}} = \frac{\bar{c}_{ki}}{\bar{c}_i}, \text{ или } K2_{\text{качество}} = \frac{\bar{c}_{kj}}{\bar{c}_j},$$

где $K2_{\text{качество}}$ – коэффициент качества, ki и kj – индексы кластеров исследуемого класса качества, с дифференцированием, соответственно, по местоположению или по размеру.

Нетрудно показать, что преобразование полученных уравнений приводит к трем простым формулам расчета:

$$C = \bar{c}_i \times K2_{\text{размер}} \times K2_{\text{качество}} = \bar{c}_i \times \frac{\bar{c}_{ji}}{\bar{c}_i} \times \frac{\bar{c}_{ki}}{\bar{c}_i} = \frac{\bar{c}_{ji} \times \bar{c}_{ki}}{\bar{c}_i}, \text{ или}$$

$$C = \bar{c}_j \times K2_{\text{место}} \times K2_{\text{качество}} = \bar{c}_j \times \frac{\bar{c}_{ij}}{\bar{c}_j} \times \frac{\bar{c}_{kj}}{\bar{c}_j} = \frac{\bar{c}_{ij} \times \bar{c}_{kj}}{\bar{c}_j}, \text{ или}$$

$$C = \bar{c}_k \times K2_{\text{место}} \times K2_{\text{размер}} = \bar{c}_k \times \frac{\bar{c}_{ik}}{\bar{c}_k} \times \frac{\bar{c}_{jk}}{\bar{c}_k} = \frac{\bar{c}_{ik} \times \bar{c}_{jk}}{\bar{c}_k}.$$

Аналогично, если погрешность в определении средней в кластере второго уровня сечения превышает допустимую или объекты-аналоги в кластере

вообще отсутствуют, расчет удельной цены (ставки аренды) оцениваемого объекта осуществляется путем применения коэффициентов ценовых поправок первого уровня к среднему значению исходной выборки (нулевого уровня):

$$C = \bar{C} \times K1_{\text{место}} \times K1_{\text{размер}} \times K1_{\text{качество}}.$$

Для каждого из факторов определяется ценовая поправка по данному фактору как коэффициент отношения среднего значения удельной ставки аренды в интересующей подвыборке к среднему значению в исходной выборке:

$$K1_{\text{место}} = \frac{\bar{c}_i}{\bar{c}},$$

где $K_{\text{место}}$ – коэффициент местоположения, i – индекс исследуемой территориальной зоны;

$$K1_{\text{размер}} = \frac{\bar{c}_j}{\bar{c}},$$

где $K_{\text{размер}}$ – коэффициент размера, j – индекс диапазона площадей;

$$K1_{\text{качество}} = \frac{\bar{c}_k}{\bar{c}},$$

где $K_{\text{качество}}$ – коэффициент качества, k – индекс класса.

При подстановке формул для коэффициентов в формулы для расчета средней удельной цены (ставки аренды) первого уровня сечения величина среднего значения исходной выборки \bar{C} и любой один из коэффициентов сокращаются, оставляя три варианта конечных уравнений:

$$C = \bar{c}_i \times K1_{\text{размер}} \times K1_{\text{качество}}, \text{ или}$$

$$C = \bar{c}_j \times K1_{\text{место}} \times K1_{\text{качество}}, \text{ или}$$

$$C = \bar{c}_k \times K1_{\text{место}} \times K1_{\text{размер}}.$$

Из изложенного следует, что искомая удельная цена (ставка аренды) для случая трехуровневого сечения может вычисляться семью разными вариантами расчета, в зависимости от объема данных:

1. $C = \bar{c}_{ijk}$, если в кластере третьего уровня сечения погрешность меньше или равна допустимой ($\delta \leq 10-15\%$ – развитые рынки крупных городов);

2. $C = \{ \bar{c}_i \times K2_{\text{размер}} \times K2_{\text{качество}}, \text{ или } \bar{c}_j \times K2_{\text{место}} \times K2_{\text{качество}}, \text{ или } \bar{c}_k \times K2_{\text{место}} \times K2_{\text{размер}} \}$, если в кластере третьего уровня сечения погрешность больше допустимой и в кластерах второго уровня сечения погрешность меньше допустимой (рынки средних городов);

3. $C = \{ \bar{c}_i \times K1_{\text{размер}} \times K1_{\text{качество}}, \text{ или } \bar{c}_j \times K1_{\text{место}} \times K1_{\text{качество}}, \text{ или } \bar{c}_k \times K1_{\text{место}} \times K1_{\text{размер}} \}$, если в кластере второго уровня сечения погрешность больше допустимой либо выборка вообще отсутствует, и в кластерах первого уровня сечения меньше или равна (рынки малых городов).

В связи с представленной вариантноностью расчетов легко показать, что все варианты дают один и тот же результат, в связи с чем необходимость в многовариантном расчете отпадает.

Таким образом, для каждого объекта искомая среднерыночная удельная цена (арендная ставка) объектов-аналогов конечного кластера равна

$$C = \bar{C} \times K1 \times K2 \times K3,$$

где \bar{C} – средневзвешенная по площади удельная цена (ставка аренды) выбранного по настоящей методике кластера в локальном сегменте рынка; **K1, K2, K3** – рассчитанные по настоящей методике поправочные коэффициенты, соответственно – местоположения, размера и качества помещения.

Заключение. Методология ДППМ развита и формализована (перешла из категории числовой в категорию расчетной). Разработанная методика статического интерполяционного пространственно-параметрического прогнозирования на основе ДППМ позволяет восполнять недостающие данные в нерепрезентативных кластерах и в кластерах с отсутствующей выборкой. Разработанная методика расширяет возможности комплексного алгоритма анализа рынка и оценки объектов недвижимости.

Библиографический список

1. Стерник Г.М. Методические рекомендации по анализу рынка недвижимости. – РГР, 1999. – 60 с.
2. Стерник Г.М. Технология анализа рынка недвижимости. –М., Изд. АКСВЕЛЛ, 2005. – 203 с.
3. Стерник Г.М., Стерник С.Г. Анализ рынка недвижимости для профессионалов. – М.: Изд. «Экономика», 2009. – 606 с.
4. Грибовский С.В., Федотова М.А., Стерник Г.М., Житков Д.Б. Методология массовой оценки квартир для налогообложения. – «Бюллетень финансовой информации» № 1 (116), 2005, стр. 14-29.
5. Грибовский С.В., Федотова М.А., Стерник Г.М., Житков Д.Б. Экономико-математические модели оценки недвижимости. – «Финансы и кредит» 3 (171), 2005, стр. 24-43.
6. Стерник С.Г. Развитие системы статистических индексов в финансовом анализе инвестиций на рынке недвижимости. Финансы и кредит. 2009. № 40 (376). С. 71-75.
7. Стерник Г.М., Стерник С.Г. Массовая оценка недвижимости для целей налогообложения: проблемы и пути их решения. – Материалы III Поволжской научно-практической конференции «Статистические методы массовой оценки». Нижний Новгород, октябрь 2009, стр. 68-76.
8. Стерник С.Г. Развитие оценки недвижимости сравнительным подходом на основе методологии дискретного пространственно-параметрического анализа и моделирования рынка. Аудит и финансовый анализ. 2009. № 5. С. 130-137.
9. Стерник Г.М., Стерник С.Г. Оценка недвижимости на основе методологии дискретного пространственно-параметрического моделирования рынка. – Журнал «Регистр оценщиков», №2, 2010, стр. 74-78.

- 10.Стерник Г.М., Стерник С.Г. Актуальные проблемы теории и практики массовой оценки недвижимости для целей налогообложения. Имущественные отношения в Российской Федерации. 2010. № 10 (109). С. 47-57.
- 11.Стерник С.Г., Стерник Г.М., Лапко К.С. Массовая оценка недвижимости для целей налогообложения: проблемы и пути их решения. Финансовая аналитика: проблемы и решения. 2010. № 12 (36). С. 2-12.
- 12.Стерник Г.М., Стерник С.Г. Оценка ставок аренды коммерческой недвижимости на узких рынках. – Вестник Финансового университета. 2015. № 5. С. 73-79.
- 13.Стерник Г.М., Стерник С.Г. Методология моделирования и прогнозирования жилищного рынка: монография. – Москва: «РГ-Пресс», 2018. – 592 с.

STATIC INTERPOLATION MODELLING OF REAL ESTATE MARKET PARAMETERS USING DISCRETE SPATIAL-PARAMETRIC MODEL (DSPM)

Sternik Sergey Gennad'evich

Financial university under Government of Russian Federation, 125993, Moscow, Leningradsky av., bldg.49, sergey-sternik@yandex.ru

Article presents application of discrete spatial-parametric model (DSPM) for real estate market monitoring, building of dynamic real estate indices and mass-valuation of real estate. Methodology is based upon statistical cluster analysis and allows implementing static discrete spatial-parametric interpolation inside small clusters with insufficient sample size as well as narrow markets with constrained or absenting supply.

Keywords: real estate market, cluster analysis, monitoring, modelling, forecasting, mass valuation, dynamic indices, small sample

СОЗДАНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ДОРОЖНО-ТРАНСПОРТНЫХ ПРОИСШЕСТВИЙ

Авраменко Дарья Георгиевна,

Пермский государственный национальный исследовательский университет,
ПМИ. Россия, г. Пермь, 614990, ул. Букирева, 15,
AvramenkoDasha@yandex.ru

Разработана нейросетевая модель прогнозирования дорожно-транспортных происшествий. Из исследования модели было выяснено, что наиболее значимыми параметрами являются непосредственные нарушения правил дорожного движения, степень опьянения, сопутствующие нарушения правил. Наименьшую значимость имеет погода.

Ключевые слова: искусственный интеллект; нейронная сеть; модель; дорожно-транспортные происшествия.

Введение

Автомобильный транспорт является самым небезопасным из всех, доступных человеку. По всем данным именно дорожно-транспортные происшествия (ДТП) ставят на первое место по числу погибших и пострадавших. По этим параметрам автомобили значительно обгоняют железнодорожный, авиационный и водный транспорт.

Дорожно-транспортные происшествия являются основной причиной гибели людей. Они происходят по многим причинам, среди которых есть как технологические, так и человеческие факторы. Авария может случиться по вине уставшего водителя, из-за обледенения дорожного покрытия или неисправности тормозной системы. Однако на риск попасть в ДТП часто влияют сторонние факторы – такие как день недели, погодные условия и качество асфальтового покрытия.

Выявление факторов, значимо влияющих на риск дорожно-транспортного происшествия при решении задачи повышения безопасности на дорогах должно рассматриваться как приоритетная задача. Это позволит принимать решения, которые действительно смогут устранить сторонние причины аварий. Анализ и выявлению подобных причин и посвящена данная работа.

Нейрокомпьютерные и нейросетевые технологии – это одна из наиболее эффективных стратегий искусственного интеллекта. Они наследуют от своего прототипа – мозга, его полезные свойства: способность извлечения знаний из статистических данных, способность обобщения их в виде законов и закономерностей предметных областей, свойство интуиции [1], как способность делать правильные прогнозы и принимать верные

решения в тех случаях, когда обычная логика оказывается бессильной. Как убедительно показывает опыт использования нейросетей ([3, 4], www.PermAi.ru), хорошо спроектированные и правильно обученные нейронные сети способны самостоятельно выявлять закономерности практически любых предметных областей и строить адекватные математические модели в промышленности, в экономике и бизнесе, в политологии, в криминалистике, в медицине, в экологии, в исторических науках, спорте и др.

Математическая постановка задачи

В результате анализа рапортов ГИБДД были выделены следующие параметры, влияющие на возникновения дорожно-транспортных происшествий:

- x_1 – Состояние погоды;
- x_2 – Освещение;
- x_3 – Пол водителя;
- x_4 – Водительский стаж;
- x_5 – Непосредственные нарушения ПДД;
- x_6 – Степень опьянения;
- x_7 – Сопутствующие нарушения ПДД;
- y – Вид ДТП.

Среди входных параметров модели имеются качественные и количественные факторы. Качественные показатели были зашифрованы следующим образом: «Состояние погоды»: ясно – 1, пасмурно – 2, дождь – 3, снегопад – 4; «Освещение»: светлое время суток – 1, темное время суток – 2; «Пол водителя»: мужской – 1, женский – 2; «Непосредственные нарушения ПДД»: нет нарушений – 0, выезд на полосу встречного движения – 1, нарушение правил расположения ТС на проезжей части – 2, несоблюдение очередности проезда – 3, неправильный выбор дистанции – 4, несоблюдение бокового интервала – 5, несоблюдение условий, разрешающих движение транспорта задним ходом – 6, нарушение правил проезда пешеходного перехода – 7, несоответствие скорости конкретным условиям движения – 8, превышение установленной скорости движения – 9, нарушение правил перестроения – 10; «Сопутствующие нарушения ПДД»: нет нарушений – 0, управление ТС лицом, не имеющим права на управление ТС – 1, управление ТС в состоянии наркотического опьянения – 2, несоблюдение требований ОСАГО – 3, оставление места ДТП – 4. Количественные показатели «Водительский стаж» и «Степень опьянения» представляют собой целые числа.

Выходная переменная y принимает значение, равное виду ДТП: нет ДТП – 0, наезд – 1, опрокидывание – 2, столкновение – 3.

В качестве источника информации для обучения нейронной сети были использованы данные рапортов ГИБДД.

На основании этой информации было сформировано множество примеров. Все множество было разбито на обучающее, которое использовалось для обучения сети, и тестирующее, которое использовалось для проверки ее прогностических свойств. Примеры тестирующего множества при обучении сети не использовались.

Проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью выполнялись с помощью нейропакета [2]. Оптимальная структура нейронной сети представляла собой персептрон [3], имеющий семь входных нейронов, два скрытых слоя по три нейрона на каждом и один выходной нейрон. В качестве активационных функций нейронов скрытого слоя и выходного нейрона использовалась функция гиперболического тангенса. После обучения, прогностические свойства сети проверялись на тестирующих примерах, и среднеквадратичная ошибка тестирования нейронной сети составила 1,6%.

Обучение и тестирование нейронных сетей проводилось согласно методике, принятой в Пермской научной школе искусственного интеллекта ([3-4], www.PermAi.ru).

3. Исследование предметной области

После того как работа нейронной сети проверена на тестовых примерах и, следовательно, подтверждена адекватность нейросетевой математической модели, можно приступить к ее исследованию. Обученная нейросетевая модель реагирует на изменение входных переменных и ведет себя так же, как вела бы себя сама предметная область.

Первый вопрос, на который можно получить ответ с помощью модели – выявить значимость входных параметров, т.е. – степень их влияния на результат моделирования – вид ДТП. Объективную оценку такого влияния можно получить, например, по методике [3] с помощью той же нейронной сети путем поочередного исключения или изменения входных параметров и наблюдением за погрешностью ее тестирования. Чем выше оказывается погрешность тестирования, тем значимее соответствующий исключенный параметр. Построенная таким образом гистограмма приведена на рисунке 1. Высота столбцов соответствует погрешности тестирования, полученной при измененном входном параметре, подписанном под столбцом, поэтому ее можно интерпретировать как значимость этого параметра.




Рисунок 1. Значимость параметров построенной нейросети

Как видно из рисунка, наиболее значимыми параметрами являются – непосредственные нарушения ПДД, степень опьянения, сопутствующие нарушения ПДД.

При сравнении действительных дорожно-транспортных происшествий и прогнозируемых возникают достаточно небольшие отклонения (рисунок 2), поэтому можно сделать вывод о том, что прогнозируемое значение достаточно точно определяется обученной нейросетью, т.к. погрешность тестирования составляет 1,6%.




Рисунок 2. Сравнение фактических и прогнозируемых дорожно-транспортных происшествий

На рисунках 3 – 5 приведены результаты дальнейших исследований нейросетевой математической модели, построенной с учетом всех входных параметров. Исследование влияния изменения входных параметров на результат дорожно-транспортного происшествия выполнены путем «замораживания» (фиксации) одних параметров и постепенного изменения других входных параметров при одновременном наблюдении за значением выхода сети.

На рисунке 3 приведены результаты компьютерных экспериментов для женщины с водительским стажем 2 года, которая ехала в светлое время суток, не нарушая ПДД.





Рисунок 3. Зависимость дорожно-транспортных происшествий от погоды

На рисунке 4 приведены результаты компьютерных экспериментов для мужчины с водительским стажем 15 лет, который ехал ясную погоду в темное время суток.



Непосредственные нарушения ПДД

Рисунок 4. Зависимость дорожно-транспортных происшествий от непосредственных нарушений ПДД

На рисунке 5 приведены результаты компьютерных экспериментов для мужчины с водительским стажем 3 года, который ехал в ясную погоду в светлое время суток.




Рисунок 5. Зависимость дорожно-транспортных происшествий от непосредственных нарушений ПДД

4. Заключение

Разработана нейросетевая математическая модель, предназначенная для прогнозирования дорожно-транспортных происшествий, которая может быть полезна для повышения безопасности на дорогах или для страховых компаний, планирующих введение программ страхования жизни и здоровья водителей и пассажиров.

Библиографический список

1. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
2. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
3. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
4. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь: Пермский университет, 2007. 271с.
5. <http://stat.gibdd.ru/>

CREATION OF NEURAL NETWORK FOR PREDICTING TRAFFIC ACCIDENTS

Avramenko Daria G.

Perm State National Research University
614990, Russia, Perm, street Bukireva, 15, AvramenkoDaha@yandex.ru

A neural network model for predicting traffic accidents has been developed. From the study of the model, it was found that the most significant parameters are direct traffic violations, the degree of intoxication, and related traffic violations. The least significant is the weather.

Key words: artificial intelligence; neural network; model; traffic accidents.

УДК-324

ПРОГНОЗИРОВАНИЕ ПРОЦЕНТА ГОЛОСОВ, ПОЛУЧЕННОГО ПАРТИЕЙ В ХОДЕ ВЫБОРОВ В ГОСУДАРСТВЕННУЮ ДУМУ, С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

Халдина Юлия, Скоробогатова Маргарита

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, khaldunaskara@psu.ru,
skorobogatovamm@psu.ru

В статье представлено описание создания нейросетевой системы для прогнозирования процента голосов, которые получит партия в ходе голосования по партийным спискам на выборах в Государственную Думу. Учитывая идеологию партии, её отношение к действующей власти, опыт политической деятельности, а также социальную и экономическую ситуацию в стране, система позволяет спрогнозировать процент голосов, который получит партия в ходе выборов. Над полученной системой был проведён ряд исследований, результаты которых также приводятся в этой статье.

Ключевые слова: искусственный интеллект, нейросетевые технологии, выборы в государственную думу, прогнозирование.

Введение. Целью работы является создание нейросетевой системы для прогнозирования процента голосов, которые получит партия в ходе голосования по партийным спискам на выборах в Государственную Думу. В 2021 году будут проведены выборы в Государственную Думу VIII-ого созыва, поэтому актуальность данной работы на сегодняшний день весьма высока. Знать приблизительный результат думских выборов может быть полезно как избирателям, так и политтехнологам и политологам. Зная заранее, что партия рискует не пройти заградительный барьер, избиратель

может поменять своё мнение в пользу более перспективных участников выборов, а политические деятели могут оценить риски и изменить стратегию ещё до начала агитационного процесса, либо же сразу отказаться от участия в выборах и не тратить ресурсы на избирательную кампанию.

Искусственный интеллект уже успешно применялся в предсказании результатов выборов [1-4], но все работы ставили перед собой цель прогнозировать итоги президентских, а не думских выборов. Помимо основной темы, эти работы значительно отличаются от данной подходом к подбору параметров: большинство из них учитывают исключительно качества кандидатов (порой весьма спорные, например, стихию или знак зодиака, как в [2]), игнорируя влияние внешней среды на результат, хотя в работах [1-3] признаётся необходимость учитывать социальную и экономическую ситуацию в стране. Учитывая опыт [1,3,4], были выбраны параметры, которые можно разделить на две группы: параметры партии, для которой прогнозируется результат (такие как идеология и количество участия в выборах), и внешние параметры, оценивающие социальную и экономическую ситуацию. Информация о входных и выходных параметрах представлена в таблице 1.

Таблица 1 – Входные и выходные параметры

Параметр	Значение	Расшифровка
X1	Партия позиционирует себя как либеральная	Нет 0 Да 1
X2	Партия позиционирует себя как демократическая	Нет 0 Да 1
X3	Партия позиционирует себя как центристская	Нет 0 Да 1
X4	Партия позиционирует себя как консервативная	Нет 0 Да 1
X5	Партия позиционирует себя как социалистическая/коммунистическая	Нет 0 Да 1
X6	Партия позиционирует себя как оппозиция	Оппозиционность 0 Лояльность власти 1
X7	Партия имеет места в Думе предыдущего созыва	Нет 0 Да 1
X8	Количество участия в выборах в Думу	Число
X9	Количество успешных участия в выборах в Думу (преодолен порог в 5% или 7% в зависимости от правил проведения)	Число
X10	Сколько лет существует партия к году проведения выборов	Число
X11	Год основания партии	Число

X12	Победила ли партия на прошлых выборах	Нет 0 Да 1
X13	Номер месяца проведения выборов	Число
X14	Стоимость доллара в рублях в месяц проведения выборов	Число
X15	Индекс восприятия коррупции (ближайшая оценка к году проведения выборов по версии Трансперенси Интернешнл Россия [5])	Число
X16	Цена на нефть марки Brent в месяц проведения выборов	Число
X17	Индекс свободы прессы (ближайшая оценка к году проведения выборов по версии WORLD PRESS FREEDOM INDEX [6])	Число
X18	Заградительный барьер в текущем году (сколько процентов голосов должна набрать партия для прохода в думу)	Число
X19	Количество конкурентов (количество участвующих в голосовании партий и избирательных блоков)	Число
D1	Процент голосов, полученный партией в ходе выборов в Государственную Думу	Число

Параметры X1-X6 отображают идеологию партии, то, как она позиционирует себя в агитации и какие у неё отношения с текущей властью. X7-12 отображают опыт партии на политической арене. Параметры X13, X18 и X19 – это параметры выборов. Месяц проведения выборов влияет на явку некоторых слоёв населения, и, соответственно, на процент голосов за определённые партии, а количество участвующих партий влияет на конкуренцию. X14-X16 – экономические параметры, отражающиеся на настроениях избирателей. Параметр X17 показывает, насколько свободно проходила агитация различных партий и избирательных блоков и был ли у всех участников равный доступ к традиционным СМИ.

К сожалению, сложно оценить числовыми характеристиками такие параметры, как харизматичность лидеров партии, активность агитации и креативность агитационных материалов. О многих партиях недостаточно данных, а ранние выборы слабо освещались в интернете. Также сложно оценить, насколько разной была агитация для различных партий: с

усилением цензуры в традиционных СМИ многие партии могли получить меньше экранного времени, поэтому для оценки свободы СМИ используется только параметр X17.

Выходным параметром является процент голосов, полученный партией в ходе выборов по пропорциональной системе. Количество полученных мест в ходе выборов по мажоритарной системе решено было не предсказывать, поскольку пропорциональная система голосования применялась не на всех думских выборах, что сократило бы количество данных.

Обучающее и тестовое множество. Следуя примеру работ [1,3], в качестве исходных данных были выбраны участвовавшие в выборах Государственной Думы I-VII созывов (1993-2016 гг.) партии и избирательные блоки.

Датасет для обучения и тестирования нейронной сети собирался вручную с сайтов [5-12], так как уже готового датасета на данную тему найдено не было, а единого источника информации про все партии и избирательные блоки, который можно было бы обработать программой-парсером, не существует. О небольшой части когда-то участвовавших в выборах партий и избирательных блоках не было найдено достаточно информации, поэтому они не использовались в обучении.

Полученный датасет содержит 109 записей. Датасет был перемешан и разделён на обучающее множество из 97 записей и тестовое – из 12 записей.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [13]. Полученная нейронная сеть персептронного типа имеет 19 нейронов во входном слое, 2 – в первом скрытом слое, 1 – во втором скрытом слое и 1 – в выходном слое. Для обучения использовался алгоритм упругого распространения. Средняя относительная квадратичная погрешность обучения составила 3,4437%, тестирования – 14,5256%. Результаты тестирования приведены на рисунке 1.




Рисунок 1 – Результаты тестирования

Из результатов тестирования можно сделать вывод, что нейронная сеть нашла необходимые зависимости и корректно прогнозирует процент, который получит партия в ходе голосования. Неточности в предсказании связаны с тем, что не были учтены многие параметры, о чём было сказано выше.

Оценка значимости параметров выполнена с помощью программы «Нейросимулятор 5», результат отображён на рисунке 2. Одними из самых значимых параметров оказались год основания партии и количество участия в выборах. Это параметры, отражающие опытность партии. Также на процент голосов значительно влияет консерваторская позиция партии.




Рисунок 2 – Значимость параметров

Обученная нейронная сеть была применена для прогнозирования выборов в Государственную Думу VIII-ого созыва, которые будут проведены в 2021 году. Были выбраны 13 партий, данные которых представлены в таблице 2.

Таблица 2 – Параметры партий

Название партии	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12
Гражданская платформа	1	0	0	1	0	1	0	1	0	9	2012	0
Единая Россия	0	0	1	1	0	1	1	5	5	20	2001	1
Зелёные	0	0	1	0	0	1	0	4	0	28	1993	0
Коммунисты России	0	0	1	0	0	1	0	4	0	28	1993	0
КПРФ	0	0	0	0	1	0	1	7	7	31	1990	0
ЛДПР	1	1	0	1	0	0	1	7	7	32	1989	0
Партия роста	1	0	0	1	0	1	0	1	1	5	2016	0
Патриоты России	0	1	0	0	1	1	0	4	0	16	2005	0
Родина	0	0	0	1	0	1	0	3	1	18	2003	0
Российская партия пенсионеров за социальную справедливость	0	1	0	1	1	1	0	3	0	24	1997	0
Справедливая Россия	0	1	1	0	1	0	1	3	3	15	2006	0
Яблоко	1	1	1	0	0	0	0	7	3	28	1993	0

Коммунистическая партия социальной справедливости	0	0	0	0	1	1	0	0	0	9	2012	0
---	---	---	---	---	---	---	---	---	---	---	------	---

В качестве внешних параметров были выбраны прогнозируемые цены на нефть (около 50 рублей) и на доллар (74,7 руб.), индексы взяты за 2020 год. Заградительный барьер, который будет действовать в 2021 году, а также месяц проведения голосования уже известны.

Результаты прогнозирования представлены на рисунке 3. Как видно из графика, Единая Россия не потеряет конституционного большинства, ЛДПР и КПРФ чуть сдадут позиции, а остальные партии не смогут преодолеть заградительный барьер. Результаты вполне ожидаемые и логичные.




Рисунок 3 – Прогноз результатов выборов 2021 года

Далее были проведены исследования влияния различных параметров на процент голосов, который наберут наиболее популярные ныне партии: Единая Россия, КПРФ и ЛДПР. На рисунке 4 представлена зависимость прогнозируемого процента голосов от идеологии партии Единая Россия. Если партия начнёт позиционировать себя как либеральная или перестанет быть консерваторской, она значительно потеряет в популярности, но всё ещё будет набирать более 5% голосов. В случае, когда партия будет позиционировать себя как демократическая, результат голосования поменяется незначительно.




Рисунок 4 – Зависимость процента голосов от идеологии партии Единая Россия

На рисунке 5 представлена зависимость прогнозируемого процента голосов от идеологии партии ЛДПР. Если партия перестанет быть либеральной, демократической, или начнёт позиционировать себя как центристская, процент голосов упадёт ниже 5%, а в случае отказа от консервативной идеологии результат почти не изменится.




Рисунок 5 – Зависимость процента голосов от идеологии партии ЛДПР

На рисунке 6 представлена зависимость прогнозируемого процента голосов от идеологии партии КПрФ. Если партия начнёт позиционировать себя как либеральная, консервативная или демократическая, процент незначительно повысится, а в случае использования центристской идеологии результат партии резко упадёт и станет ниже 5% голосов.




Рисунок 6 – Зависимость процента голосов от идеологии партии КПрФ

На рисунке 7 представлена зависимость процента голосов от месяца проведения голосования. Полученные результаты легко объясняются более низкой явкой пожилого населения (основного электората выбранных партий) в период дачного сезона (сентябрь).




Рисунок 7 – Зависимость процента голосов от месяца проведения голосования

На рисунке 8 представлена зависимость процента голосов от победы на предыдущих выборах. Если бы Единая Россия не победила в думских выборах 2016 года, она набрала бы значительно меньше голосов в 2021. Победа в предыдущих выборах принесла бы партиям ЛДПР и КПрФ незначительный прирост процента голосов.




Рисунок 8 – Зависимость процента голосов от победы на предыдущих выборах

На рисунке 9 представлена зависимость процента голосов от оппозиционности партии. Единая Россия потеряет незначительное количество процентов, если начнёт оппозиционную деятельность. Партии КПРФ и ЛДПР, позиционирующие себя как оппозиционные, потеряют значительную часть голосов, если станут лояльны к текущей власти. В случае с ЛДПР получится так, что партия не наберёт даже 5% голосов.




Рисунок 9 – Зависимость процента голосов от оппозиционности партии

Заключение. В ходе работы была создана нейросетевая система, позволяющая спрогнозировать процент голосов, который получит партия в ходе голосования по партийным спискам на выборах в Государственную Думу. В отличие от предыдущих работ [1-4], данная работа учитывает

экономическую и социальную ситуацию, также влияющую на итоги выборов, например, различные международные рейтинги и цены на доллар и на нефть.

На основании созданной модели были спрогнозированы результаты выборов 2021 года, а также исследования, позволяющие определить, какие параметры сильнее влияют на результаты выборов и на что политтехнологам стоит обратить внимание. Полученная модель будет полезна как избирателям, так и политическим деятелям.

Библиографический список

1. Ясницкий Л.Н. О возможностях применения методов искусственного интеллекта в политологии // Вестник Пермского университета. Политология. – 2008. – Вып.2 (4). – С. 147-155.
2. Гомзяков А. Применение нейронных сетей для прогнозирования результатов президентских выборов // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. – 2018. – С. 200-206.
3. Ясницкий Л.Н., Черепанов Ф.М. О возможностях применения нейросетевых технологий в политологии // Нейрокомпьютеры: разработка и применение. – 2010. – №8. – Вып. 4. – С. 47-53.
4. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. – 221 с.
5. Индекс Восприятия Коррупции. URL: <https://transparency.org.ru/research/indeks-vozpriyatiya-korruptsii/>
6. World Press Freedom Index. URL: <https://rsf.org/en/ranking>
7. Википедия: Категория:Выборы в Государственную думу РФ. URL: https://ru.wikipedia.org/wiki/Категория:Выборы_в_Государственную_думу_РФ
8. Википедия: Категория:Политические партии России. URL: https://ru.wikipedia.org/wiki/Категория:Политические_партии_России
9. Электронная библиотека ГПИБ России: Федеральные выборы. URL: <http://elib.shpl.ru/ru/nodes/12579-federalnye-vybory>
10. Информационно-исследовательский центр "Панорама". URL: <http://www.panorama.ru/index.html>
11. Динамика цены на нефть Брент (Brent). URL: <https://calc.ru/dinamika-Brent.html>
12. Курсы валют в динамике. URL: <https://ratestats.com/>
13. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

FORECASTING THE PERCENTAGE OF VOTES RECEIVED BY THE PARTY DURING ELECTIONS TO THE STATE DUMA BY USING NEURAL NETWORKS

Khaldina Julia A., Skorobogatova Margarita M.
Perm State University, Str. Bukireva, 15, Perm, Russia, 614990,
khaldunaskara@psu.ru, skorobogatovamm@psu.ru

The article describes the creation of a neural network system for predicting the percentage of votes that a party will receive during the voting on party lists in the elections to the State Duma. Given the party's ideology, its attitude to the current government, the experience of political activity, as well as the social and economic situation in the country, the system allows us to predict the percentage of votes that the party will receive during the election. A number of studies were conducted on the resulting system, the results of which are also given in this article.

Key words: artificial intelligence, neural network technologies, elections to the State Duma, forecasting.

УДК 004.0323.26

РАЗРАБОТКА И ПРИМЕНЕНИЕ КОМПЛЕКСНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ МАССОВОЙ ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ СТОИМОСТИ ЧАСТНЫХ ДОМОВ НА ПРИМЕРЕ РЫНКОВ НЕДВИЖИМОСТИ ПЕРМСКОГО КРАЯ

Шукшина Мария Ивановна, Ясницкий Леонид Нахимович
Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, mm.shukshina@yandex.ru

Работа посвящена исследованию возможностей применения метода экономико-математического моделирования массовой оценки жилой недвижимости Пермского края, в частности – для прогнозирования стоимости частной недвижимости, выявлению факторов, влияющих на стоимость частной недвижимости. Среднеквадратичная относительная ошибка модели составила 9,49%. Компьютерные эксперименты выполнены методом «замораживания»: с помощью нейронной сети производились вычисления при виртуальном изменении одного из входных параметров модели, например – вид отопления, тогда как остальные входные параметры сохранялись неизменными. Оказалось, что виртуальное изменение удаленности от города по-разному сказывается на прогнозируемых стоимостях домов. По-разному влияют на стоимость частного дома и другие параметры. На основании компьютерных экспериментов предложен ряд

рекомендаций, которые могли бы способствовать повышению стоимости домов.

Ключевые слова: искусственный интеллект, нейросетевые технологии, рынок частной недвижимости, оценка стоимости, прогнозирование, жилая недвижимость.

Анализ литературы показал, что имеется большое количество работ, отмечающих важность и актуальность создания высокоточных методик массовой оценки объектов недвижимости. В работе [1] (Австралия, 2010) приведен обзор международной литературы, а также интервью с государственными деятелями и оценщиками многих государств, из которых следует, что системы массовой оценки и налогообложения недвижимости являются «важной и прочной базой для повышения государственных доходов».

В 1992 году A.Q.Do и G.Grudnitski [2] опубликовали сообщение о том, что для оценки недвижимости США ими был использован персептрон имеющий восемь входных нейронов для ввода характеристик объекта недвижимости: площадь объекта, количество этажей, площадь земельного участка и т.д. Персептрон имел один скрытый слой с тремя сигмоидными нейронами. Сообщается о том, что на тестовом множестве из 105 домов «нейросетевая модель имела в два раза большую точность предсказанных значений, чем аналогичная регрессионная модель». В результате, был сделан вывод, что «для оценки стоимости недвижимости нейронная сеть подходит лучше, чем многомерная регрессионная модель».

В 2015 году В.Л.Ясницкий опубликовал статью [3] с сообщением о создании нейросетевой математической модели, реализованной в виде компьютерной программы. Программа предназначена для массовой оценки рыночной стоимости жилой недвижимости г. Перми со средней относительной погрешности 1,03%. Исследования модели показали, что из четырнадцати входных параметров наиболее значимыми являются: площадь квартиры, тип и серия жилого дома, а также этаж.

При создании экономико-математической модели, предназначенной для прогнозирования массовой оценки жилой недвижимости Пермского края, был принят во внимание опыт, отраженный в приведенном выше кратком обзоре литературы. В качестве входного множества был подобран список из 428 частных домов со стоимостью в диапазоне от 230 тысяч до 15 миллионов рублей. Это множество разбивалось на два, обучающее, содержащее 350 примеров, и тестирующее, содержащее 56 примеров. Остальные примеры были выброшены из выборки. Необходимые данные о частных домах были получены с сайта www.avito.ru [4] и perm.cian.ru [5], которые предоставляют всю необходимую информацию о продаже домов. Таким образом, при разработке нейросетевой экономико-математической модели мы использовали следующие входные параметры и систему кодирования их значений:

x_1 – Материал, из которого изготовлен дом: 1 – кирпич, 2 – газоблоки, 3 – брус, 4 – блокхаус, 5 – пеноблоки, 6 – Сэндвич-панели.

x_2 – Площадь дома, м².

x_3 – Количество комнат.

x_4 – Количество этажей.

x_5 – Площадь участка, сотка.

x_6 – Разработан ли земельный участок: 0 – нет, 1 – да.

x_7 – Вид отопления: 0 – печное, 1 – газовое, 2 – электрическое,

x_8 – Наличие гаража: 0 – нет, 1 – есть.

x_9 – Наличие бани: 0 – нет, 1 – есть.

x_{10} – Удаленность от города, км.

x_{11} – Вид объекта: 1 – коттедж, 2 – дом, 3- дача.

Выходная переменная модели у соответствует заявленной цене объекта недвижимости.

Оптимальная структура нейронной сети, созданной в среде [8] представляла собой персептрон, изображенный на рис. 1, имеющий одиннадцать входных нейронов, один скрытый слой с двумя нейронами, а также один выходной нейрон. В качестве активационных функций нейронов скрытого слоя и выходного слоя использовался тангенс гиперболический, а в качестве алгоритма обучения – алгоритм упругого распространения.




Рисунок 1. Нейронная сеть – персептрон с одиннадцатью входными нейронами, одним выходным нейроном и двумя нейронами скрытого слоя

Для оценки качества нейронной сети использовалась среднеквадратичная относительная погрешность, рассчитываемая с помощью формулы:

$$E = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - y_n)^2}{N}}}{|\max(d_n) - \min(d_n)|} 100\% , \quad (1)$$

в которой N – количество элементов выборки, d_n – заявленная стоимость n -й квартиры, y_n – ее стоимость, оцененная с помощью нейронной сети. Причем, эта ошибка рассчитывалась как на обучающем, так и на тестирующем множествах. Среднеквадратичная относительная погрешность на обучающем множестве примеров составила 9,49%, а на тестовом 12,1%.

Поскольку примеры тестирующего множества не использовались при обучении нейронной сети, можно утверждать, что нейронная сеть усвоила закономерности моделируемой предметной области, и теперь ее можно использовать для проведения вычислительных экспериментов.

В процессе обучения и тестирования нейросети были обнаружены выбросы, выявленные с помощью методики [6]. Суть этой методики состоит в поочередном исключении примеров из обучающего множества и наблюдении за погрешностью нейросети, обученной на этих урезанных множествах. Если пример обучающего множества является выбросом и выпадает из закономерности, характерной для исследуемой предметной области, то его удаление из обучающего множества приводит к падению погрешности обучения сети и повышению ее обобщающих свойств, тогда как исключение обычных примеров существенного влияния на качество сети, как правило, не оказывает. В качестве выбросов нейросетевой фильтр часто фиксировал дома стоимостью более 7,5 миллионов рублей.

Коэффициент детерминации R^2 на тестовом множестве (между предсказанными и наблюдаемыми значениями) составил 0,809, что говорит о том, что построенная аппроксимирующая модель описывает рынок объясняющими входными переменными на 80,9%.

Один из результатов тестирования, выполненного на 56 тестовых примерах, в графическом виде представлен на рисунках 2 – 3, из которых видно, что оценки домов, выполненные нейронной сетью, незначительно отличаются от фактических (заявленных) значений стоимостей частных домов. На рисунке 4 приведен другой способ визуализации результатов тестирования сети – диаграмма рассеяния. По горизонтальной оси отложены реальные стоимости домов тестирующего множества, а по вертикальной – их оценки, выполненные нейронной сетью. По этому рисунку также можно судить, что нейронная сеть усвоила закономерности рынка недвижимости Пермского края и является вполне приемлемой, хотя и не идеальной.

Еще раз отметим, что данные о параметрах квартир тестового множества не были использованы при обучении нейронной сети, т.е. они являются новыми и поэтому на них проверяются прогностические свойства

нейронной сети. Кроме того, обратим внимание, что количество примеров обучающего множества удовлетворяет требованию репрезентативности [7]: оно значительно больше чем $7N_x+15$, где N_x – число входных параметров.



Рисунок 2. Пример тестирования сети: сопоставление заявленных и оцененных с помощью нейросети стоимостей домов (часть 1)




Рисунок 3. Пример тестирования сети: сопоставление заявленных и оцененных с помощью нейросети стоимостей домов (часть 2)




Рисунок 4. Диаграмма рассеяния

Экспериментальная часть. Обученная нейросетевая модель реагирует на изменение входных переменных и ведет себя так же, как вела бы себя сама предметная область. Выяснить значимость входных параметров, т.е. – степень их влияния на результат моделирования – стоимость частных домов в Пермском крае можно, например, по методике [6] с помощью той же нейронной сети путем поочередного исключения входных параметров и наблюдения за погрешностью ее тестирования. Чем выше оказывается погрешность тестирования, тем значимее соответствующий исключенный параметр. Построенная таким способом гистограмма приведена на рисунке 4. Высота столбцов соответствует погрешности тестирования, полученной при исключенном входном параметре, подписанном под столбцом, поэтому ее можно интерпретировать как значимость этого параметра.




Рисунок 5. Значимость входных параметров, вычисленная с помощью нейронной сети

Как видно из рисунка, самым значимым параметром оказалось «Гараж». Следующими по значимости идут: «Баня» и «Разработан ли земельный участок».

Применение методов нейросетевого моделирования позволяет не только выполнять прогнозы, но и ставить над моделями виртуальные компьютерные эксперименты [6], пытаться изменять эти прогнозы в наиболее благоприятную сторону. Так, варьируя входные параметры обученной нейронной сети и производя вычисления, можно сформировать конкретный список рекомендаций, способствующих увеличению стоимости жилой недвижимости.

Для выполнения компьютерных экспериментов были выбраны два дома, различающиеся своими техническими характеристиками и расположением:

- Двухэтажный кирпичный дом, с газовым отоплением, общей площадью 150 кв. м, в котором 7 комнат. Площадь участка 6 соток, имеется баня и гараж, дом находится в 9 км от города.

- Двухэтажный кирпичный дом, с электрическим отоплением, общей площадью 240 кв. м, в котором 6 комнаты. Площадь участка 11 соток, имеется гараж и баня, дом находится в 1 км от города.

На рисунке 6 приведены результаты компьютерных экспериментов, выполненные с целью изучения зависимости стоимости домов от их отдаленности от города. Как видно из рисунка, в обоих случаях стоимость увеличивается при виртуальном удалении их от города.




Рисунок 6. Зависимость стоимости домов от удаленности от города

На рисунке 7 приведены результаты вычислений, полученные при изменении площади домов. Видно, что компьютерные эксперименты выявили практически линейную зависимость стоимости обоих домов от их площади.




Рисунок 7. Зависимость стоимости домов от их площади

На рисунке 8 приведены результаты вычислений, полученные при изменении количества комнат домов. Как видно из рисунка, в обоих случаях стоимость увеличивается при виртуальном увеличении количества комнат в доме.




Рисунок 8. Зависимость стоимости домов от количества комнат

Заключение. Предложена методика и разработаны комплексные экономико-математические модели массовой оценки частных домов и дач в Пермском крае, учитывающие строительно-эксплуатационные параметры квартир.

Для других регионов и областей с помощью предлагаемой методики могут быть выполнены аналогичные исследования и прогнозы. Методика и модели могут быть полезны для профессиональных аналитиков – экспертов рынка недвижимости, научных исследователей, инвесторов, государственных органов управления.

Благодарность. Работа выполнена при поддержке гранта РФФИ 19-010-00307 «Разработка интеллектуальной самоадаптируемой системы массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости регионов РФ».

Библиографический список

1. Hefferan M.J., Boyd T. Property taxation and mass appraisal valuations in Australia – adapting to a new environment // Property Management, 2010, Vol. 28, no 3, pp. 149–162.
2. Do A. Q., Grudnitski G. A neural network approach to residential property appraisal // The Real Estate Appraiser, 1992, no 58, pp. 38–45.
3. Ясницкий В.Л. Нейросетевое моделирование в задаче массовой оценки жилой недвижимости города Перми // Фундаментальные исследования. 2015. № 10–3. С. 650–653; URL: <http://www.fundamental-research.ru/ru/article/view?id=39274> (дата обращения: 27.01.2020).
4. Интернет-сайт для размещения объявлений о товарах и услугах от частных лиц и компаний. [Электронный ресурс] URL: <https://www.avito.ru> (дата обращения: 10.02.2020).

5. Интернет-сервис для покупателей и арендаторов жилья. [Электронный ресурс] URL: <https://perm.cian.ru/> (дата обращения: 15.02.2020).
6. Ясницкий Л.Н. Введение в искусственный интеллект. – М.: Издательский центр «Академия», 2005. – 176с.
7. Дайтбегов Д.М. Компьютерные технологии анализа данных в эконометрике. М: ИНФА-М, 2008. 578 с.
8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

DEVELOPMENT AND APPLICATION OF INTEGRATED NEURAL NETWORK MODELS OF MASS EVALUATION AND FORECASTING PRICES OF PRIVATE HOUSES ON THE EXAMPLE OF REAL ESTATE MARKETS OF THE PERM REGION

Shukshina Mariia I., Yasnitsky Leonid N.

Perm State University, 15, Bukireva st., Perm, 614990, Russia,
mm.shukshina@yandex.ru

This work is devoted to the study of the possibilities of applying the method of economic and mathematical modeling of mass valuation of residential real estate in the Perm Territory, in particular, for forecasting the value of private real estate, identifying factors affecting the value of private real estate. The root mean square relative error of the model was 9.49%. Computer experiments were performed by the “freezing” method: using a neural network, calculations were performed with a virtual change in one of the input parameters of the model, for example, the type of heating, while the rest of the input parameters were kept unchanged. It turned out that the virtual change in remoteness from the city has a different effect on the projected cost of houses. Differently affect the value of a private house and other parameters. Based on computer experiments, a number of recommendations have been proposed that could help increase the value of houses.

Keywords: artificial intelligence, neural network technologies, private real estate market, cost estimation, forecasting, residential real estate.

ВОЗМОЖНОСТИ ПРОГНОЗИРОВАНИЯ ПРОДАЖ КОМПЬЮТЕРНЫХ ИГР МЕТОДАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Третьяков Вячеслав Николаевич, Зуев Олег Викторович

Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15
tretiakovslava@gmail.com, olegase123@gmail.com

В статье представлено описание разработки нейросетевой системы для оценки продаж компьютерных игр. Система позволяет прогнозировать объем мировых продаж по характеристикам как самой игры, так и ее оценок, цены. Был проведен ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: Искусственный интеллект, нейронная сеть, закономерности, компьютерная игры, количество проданных копий, оценка игр.

Введение. Сегодня, во времена технического прогресса и глобальной компьютеризации, тема влияния индустрии компьютерных игр на мировую экономику является более чем актуальной. Мировые игровые издательства крепко ухватились за рынок, где конкурируют наравне с бизнес-гигантами. Так, например, в феврале 2020 года сообщалось, что польская игровая компания CD Project Red вошла в тройку самых дорогих компаний Польши. На сегодняшний день ситуация изменилась. Разработчики стали крупнейшей компанией на Польской фондовой бирже. Конечно, свою роль сыграла ситуация с пандемией, но сам факт того, что игровое издательство стоит наравне с крупнейшими корпорациями, говорит сам за себя.

Сегодня актуальной проблемой является перенасыщения рынка огромным количеством игр весьма посредственного качества. Компании и их инвесторы вкладывают огромные средства в свои продукты. Одни преследуют цель получения прибыли, а другие – успешность и узнаваемость на рынке. Но как узнать, будет ли проект положительно воспринят аудиторией? Станет ли он окупаемым? Возможно, развитие искусственного интеллекта в сторону анализа и прогнозирования рынка компьютерных игр сможет дать ответы на поставленные вопросы.

Целью настоящей работы является попытка применения современных методов искусственного интеллекта для построения методики прогнозирования продаж компьютерных игр до ее выхода.

К данной теме имеется значительный интерес, поэтому на данную тему уже есть проведенная работа [3], наработки которой частично использовались в настоящем исследовании.

В качестве платформы для прогнозирования был выбран персональный компьютер (ПК). Безусловно, консоли и мобильные устройства занимают практически одинаковые доли в общем объеме игровой индустрии, но в удобстве анализа и сбора данных ПК дает больше возможностей.

Для сбора данных была разработана программа, работающая с API сервиса Steam Spy [7]. Steam Spy – это сервис статистики Steam на основе веб-API, предоставленный компанией Valve.

В результате анализа доступных данных был выбран следующий набор показателей: X1 – Оценка Metacritic, X2 – Цена (цент доллара США), X3 – Издатель, X4 – Дата выхода (год), X5 – Экшен, X6 – Приключения, X7 – Инди, X8 – РПГ, X9 – Симулятор, X10 – Спорт, X11 – Стратегия. Выходной параметр D1 – кол-во проданных копий (шт.).

Параметр издатель был закодирован порядковыми номерами. Каждый жанр (X5 – X11) кодируется значением 0 и 1 в зависимости от принадлежности конкретной игры к соответствующему жанру. Остальные параметры являются числовыми, поэтому для них кодировка не требуется. Изначальный объем множества включал в себя 30 674 примеров (без учета параметра X1, но с учетом параметра оценки пользователей). Так как оценка пользователей является уже фактическим результатом, она была заменена на оценку Metacritic, выставляемую критиками до выхода игры. Таким образом, итоговое множество составило 2312 примеров. Можно увидеть, что огромное кол-во данных было отброшено. Это можно обосновать тем, что большинство игр – мелкие проекты (преимущественно инди жанра), а критики рассматривают же в основном крупные.

Заметим также, что в качестве входного параметра не был взят бюджет (что сделали предшественники [3] и этим значительно сократили кол-во примеров), так как большинство компаний не предоставляют данную информацию или она ограничена на ресурсах статистики.

Данное множество было разделено на обучающее, тестирующее и подтверждающее в соотношении 80%, 10% и 10% соответственно. Собранные данные охватывают период с 1994 по 2020 год.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [1], а также платформы обработки больших данных, машинного обучения и тестовой аналитики RapidMiner [6].

В результате работы над «Нейросимулятор 5» получилась нейронная сеть, представляющая собой персептрон, который имеет одиннадцать входных нейронов, один выходной и один скрытый слой с пятью нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 209 примеров. Средняя ошибка тестирования составила 51,5% (69% у предшественников [3]). На рисунке 1 представлена гистограмма, демонстрирующая разницу

между фактической и прогнозируемой нейросетью кол-ва проданных копий случайно отобранных 30 игр из тестирующего множества.



Рисунок 1. Результат тестирования нейронной сети на «Нейросимулятор 5»

Для сравнения приведём результаты из нейросети, сделанной с помощью RapidMiner. Обучение проводилось на том же множестве, но с применением сразу несколько алгоритмов для выявления лучшего из них. Средняя ошибка тестирования итоговой нейросети составила 42,6%. К слову, у предшественников [3] она составила 42%. Результаты прогноза проданных копий для того же тестирующего множества можно увидеть на рисунке 2.




Рисунок 3. Результат тестирования нейронной сети на RapidMiner

Поскольку результаты нейросети, сделанной с помощью RapidMiner, значительно превосходят показатели нейросети, написанной на

«Нейросимулятор 5», дальнейший анализ будем проводить с помощью первой.

Оценка значимости входных параметров была выполнена с помощью программы «RapidMiner», результат отображен на рисунке 3.

Attribute	Weight
Metacritic Score	0.354
Sports	0.102
Indie	0.100
Price in cents	0.080
Release Date	0.053
RPG	0.013
Adventure	0.011
Strategy	0.007
Simulation	0.004
Publisher	0.003
Action	0.002

Рисунок 3. Значимость входных параметров нейросетевой модели

Как видно из рисунка 3, наиболее значимыми параметрами являются: оценка Metacritic, жанр спорт, жанр инди, цена, дата выхода. Остальные данные имеют небольшой вес.

Попробуем разобраться в результатах распределения веса. Безусловно, важный параметр – это оценка критиков (не всегда, но именно она составляет отношение о проекте у игроков). Цена также является критическим показателем. Немногие готовы платить огромную стоимость за игры. Далее идут жанры. Рассмотрим рисунок 4 и попробуем проанализировать распределение веса.



Рисунок 4. Распределение количества игр по жанрам

Можно заметить, что инди (наибольшее) и спорт (наименьшее) по понятным причинам имеют значение в распределении веса. Остальные же данные распределились почти в одинаковом весе. Почему же экшен и приключения имеют меньший вес? Взглянув на рисунок 5, можно предположить, что причиной является оценка Metacritic.




Рисунок 5. Распределение средней оценки игр по жанрам

Да, средняя оценка различается несильно, но, возможно, в силу остальных параметров модель подбирает именно такой вес. Дополнительные графики с распределением оценки и количества по годам представлены на рисунках 14, 15.

Далее было выполнено исследование пяти случайно выбранных игр. Исследование производилось с помощью метода «замораживания». Его суть – в изменении значения одного из параметров и фиксации всех остальных. С его помощью можно понять, как именно исследуемый параметр влияет на значение выходного параметра. Выбор пал на следующие 5 игр: «NecroVision», «Myst V: End of Ages», «Ziggurat», «Convoy», «Resident Evil 7 Biohazard». Основные характеристики игр приведены в таблице 1.

Таблица 1 – Основные характеристики игр

Название игры	NecroVision	Myst V: End of Ages	Ziggurat	Convoy	Resident Evil 7 Biohazard
Оценка Metacritic	63	80	75	72	83
Цена (цент доллара США)	499	999	1499	1499	2999
Издатель	113	480	304	493	119
Дата выхода	2009	2005	2014	2015	2017
Экшен	1	0	1	1	1
Приключение	0	1	0	1	1
Инди	0	0	1	1	0
РПГ	0	0	1	1	0
Симулятор	0	0	0	0	0
Спорт	0	0	0	0	0
Стратегия	0	0	0	1	0
Кол-во проданных копий (шт.)	131000	82000	346000	159000	884000

При помощи построенной нейросети спрогнозируем кол-во проданных копий для 5 ранее выбранных игр. Результат представлен на рисунке 6. В 3-х случаях спрогнозированное значение оказалось немного меньше реального.




Рисунок 6. Результаты оценки кол-ва проданных копий игр

На рисунке 7 показан график зависимости кол-ва проданных копий игр от оценки Metacritic. Как следует из графика, увеличение оценки приводит к росту продаж. Причем значительный рост наблюдается от 75 баллов.




Рисунок 7. Зависимость кол-ва проданных копий игр от оценки Metacritic

На рисунке 8 продемонстрирован график зависимости проданных копий игр от цены. Не учитывая нулевой цены (бесплатно), можно сказать, что в целом рост цены никак не сильно портит продажи, однако при ее росте заметен небольшой спад. Цена в большинстве формируется от бюджета игры и в будущем должна окупить затраты разработчика. В свою очередь игроки же готовы платить за хорошие и качественные проекты.




Рисунок 8. Зависимость кол-ва проданных копий игр цены

Далее мы посмотрим влияет ли имя издателя на продажи. Зачастую игроки готовы покупать игры уже у проверенных студий. Возьмем такие популярные компании, как Paradox Interactive, Rockstar Games, Activision, и 3

менее известных: Fellow Traveller, Devolver Digital, Frozenbyte. Среднюю оценку у этих издателей можно увидеть на рисунке 9.




Рисунок 9. Средняя оценка игр у издателей

Рассмотрим теперь зависимость продаж от издателя. На рисунке 10 можно увидеть рост у Rockstar Games, Fellow Traveller, FrozenByte. Глядя на рисунки 9 и 11, попробуем сделать вывод. Rockstar Games имеют хорошие оценки и приемлемую цену, Fellow Traveller и FrozenByte имеют низкие цены на свои игры, что, возможно, способствует продажам. Упадок у Activision можно связать с их ценами. Непонятным остается падение у Devolver Digital, но в целом представленный прогноз отражает реально возможные показатели влияния.




Рисунок 10. Зависимость кол-ва проданных копий игр от издателя




Рисунок 11. Средняя цена игр у издателей

Теперь попробуем проанализировать, как влияет дата выхода на продажи. Для этого нам понадобится график количества вышедших игр в разные года (Рисунок 12). Как можно заметить, пик выпускаемых игр в год был достигнут в 2016 году (учитывая это в пределе нашего множества). К 2020 году заметно резкое падение.




Рисунок 12. Распределение количества игр по годам

Посмотрим на рисунок 13. Можно увидеть рост в 2013 году для игр NecroVision и Resident Evil 7. Обе игры представляют жанр экшен без смеси с другими (исключение: Resident Evil имеет побочный жанр приключения). Почему вызван рост? Взглянем на дополнительные графики на рисунках 14 и 15. В 2013 году жанр Экшен имел успех, а также выпускалось огромное количество игр с этим жанром. Также можно видеть удержание в 2016 году и падение к 2021. Такую же ситуацию можно наблюдать на рисунке 15, когда кол-во игр в жанре экшен уменьшилось. Более подробнее данную ситуацию постараемся описать в заключении.




Рисунок 13. Зависимость продаж игр от года




Рисунок 14. Средняя оценка жанров игр по годам




Рисунок 15. Количество игр по жанрам в разные года

Посмотрим, как теперь влияют на продажи 2 весовых жанра: инди и спорт. Результаты приведены на рисунках 16 и 17. В прогнозируемые данные учтено влияние того или иного жанра. В целом способствует не сильно, но здесь необходимо учесть влияние других параметров.




Рисунок 16. Наличие жанра инди




Рисунок 17. Наличие жанра спорт

Можно ли считать спроектированную нейронную сеть пригодной для прогнозирования? Ответ неоднозначен. Во-первых, стоит учесть отсутствие важного фактора, влияющего на качество игры – бюджет. Во-вторых, маленький объем параметров. В-третьих, небольшое множество для исследования (учитывая сколько игр ежегодно добавляется на площадку Steam. Собрать все данные невозможно, т. к. у некоторых проектов отсутствуют нужные параметры). Как вы могли заметить, мы не учитывали влияние остальных жанров (то есть без инди и спорта). Это требует дополнительных исследований, ведь часто проект – это смесь нескольких жанров. С средней ошибкой 42,6% данные не влияли на результат.

Сегодня на фоне влияния различных социальных ценностей (например, толерантность) издатели пытаются угодить аудитории. Где-то это получается, а где-то влияет отрицательно. Рынок игр интересен. Можно наблюдать, как выстреливает какой-то проект от незнакомого никому разработчика, как становится популярен до этого неизвестный жанр (например, жанр Battle Royale, появившийся в 2017 году). Компаниям остается только следить за тенденциями, пробовать что-то новое и экспериментировать.

Заключение. Построена система нейросетевого оценивания продаж компьютерных игр. На основании представленной модели было проведено исследование на предмет выявления факторов, максимально влияющих на продажи игр. Проведены исследования пяти случайно выбранных игр с сайта [7]. Методами сценарного прогнозирования построены графики зависимостей кол-ва проданных копий от оценки, издателя, цены, года.

Библиографический список

1. Нейросимулятор 5.0: свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий В.Л. (РФ).
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
3. Ясницкий Л.Н., Юрков М.А. Нейросетевое моделирование прогнозирования продаж видеоигр в первую неделю после выпуска // Фундаментальные исследования. – 2019. – № 11-2. – С. 339-342
4. Сайт-агрегатор собирающий отзывы [Электронный ресурс]. – URL: <https://www.metacritic.com/> (дата обращения: 21.06.2020)
5. VGCharts [Электронный ресурс]. – URL: <http://www.vgchartz.com/gamedb/> (дата обращения: 19.06.2020)
6. Rapidminer [Электронный ресурс]. – URL: <https://rapidminer.com/>
7. SteamSpy [Электронный ресурс]. – URL: <https://steamspy.com/>
8. Индустрия компьютерных игр как часть современной мировой экономики [Электронный ресурс]. – URL: <http://student.snauka.ru/2015/09/2614>

POSSIBILITIES FOR FORECASTING COMPUTER GAMES SALES BY ARTIFICIAL INTELLIGENCE METHODS

Tretyakov Vyacheslav Nikolaevich, Zuev Oleg Viktorovich

Perm State National Research University, 614990, Russia, Perm, ul. Bukireva, 15,
tretiakovslava@gmail.com, olegase123@gmail.com

The article describes the development of a neural network system for evaluating sales of computer games. The system allows you to predict global sales by the characteristics of the game itself, as well as its estimates, prices. A number of studies have been conducted, the results of which are given in this article.

Keywords: Artificial Intelligence, neural network, patterns, computer games, the number of copies sold, game rating.

СОЗДАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ, СПОСОБНОЙ АНАЛИЗИРОВАТЬ ФАКТИЧЕСКИЕ ТЕХНОЛОГИЧЕСКИЕ ПАРАМЕТРЫ ИЗГОТОВЛЕНИЯ СТЕРЖНЕЙ ЛОПАТОК АВИАЦИОННЫХ ДВИГАТЕЛЕЙ

Голдобин Максим Алексеевич, Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15, yasn@psu.ru

В статье дано описание проблемы качества изготовления отливок лопаток авиационного газотурбинного двигателя по выплываемым моделям. Предлагается обеспечивать стабильную геометрию внутренней полости лопаток и уменьшать количество бракованных отливок, за счет определения и регулировки наиболее влияющих характеристик изготовления стержней лопаток методами искусственного интеллекта.

Ключевые слова: лопатка, качество, процесс, отливка, стержень, искусственный интеллект.

К современным авиационным и газотурбинным двигателям предъявляются высокие требования. Соответствие этим требованиям, техническое совершенство двигателя и его эксплуатационные характеристики в значительной степени определяются конструктивными особенностями и устройством его внутренних механизмов узлов и деталей.

В частности, важнейшими узлами авиационного и газотурбинного двигателя определяющим его срок службы и эксплуатационные характеристики являются турбины высокого и низкого давления [1]. К основным деталям данных узлов относятся рабочие и сопловые лопатки.

Поэтому одной из приоритетных задач является обеспечение качества отливок лопаток и соответствия их геометрии конструкторской документации.

Лопатки турбины изготавливают из литейных жаропрочных сплавов. Заготовки из литейных сплавов получают литьем по выплавляемым моделям.

В настоящее время литье по выплавляемым моделям является единственным методом, который позволяет в промышленных масштабах наиболее экономично получать заготовки рабочих и сопловых лопаток турбины, не нуждающихся в последующей обработке. Несмотря на значительный прогресс в технологии и средствах производства литых лопаток, брак в литейных цехах все еще значителен. Например, при литье охлаждаемых рабочих лопаток турбины он достигает 50%.

Типичными дефектами изготовления отливок являются: наличие пор и трещин; нарушение целостности каналов охлаждения; появление в полостях охлаждения фрагментов керамического стержня; неудовлетворительное качество кристаллизации; отклонения геометрических параметров отливки [2].

Для уменьшения количества бракованных отливок, в первую очередь необходимо обеспечить стабильную геометрию внутренней полости лопаток соответствующую КД. Геометрия внутренней полости формируется стержнем лопатки.

Проблема состоит в том, что качество стержней зависит от большого количества факторов, определяемых как характеристиками используемых материалов, так и самими параметрами процесса их изготовления. Поэтому вопрос о том, какие сочетания этих характеристик и параметров являются приемлемыми, а какие приводят к браку, заранее установить достаточно сложно.

В работе [3] для решения данной проблемы предлагается использовать современные методы искусственного интеллекта.

Процесс изготовления стержня имеет порядка 70 влияющих, в той или иной степени, на результат параметров начиная от состава стержневой массы и заканчивая условиями изготовления на разных этапах процесса.

В процессе изготовления можно выделить основные стадии:

1. Приготовление стержневой массы.
2. Прессование стержня.
3. Упаковка.
4. Обжиг.
5. Контроль.

Прессование обязательно заканчивается контрольной операцией, результатом которой становится отсеивание негодных приготовленных заготовок по причинам растрескивания массы, сколов, либо непропрессовки. Поэтому процесс в общем, для решения задачи по выявлению наиболее важных параметров изготовления стержней, можно разделить на два подпроцесса: прессование и обжиг.

В первом можно выделить около 40 входных параметров, включая состав и условия выполнения операции. Выходными же являются результаты визуального контроля на наличие трещин, сколов или непропрессовки. Трещины и сколы появляются при извлечении пресованной заготовки из формы, и можно предположить, что для появления этих дефектов необходимо сочетание одних и тех же факторов, поэтому данные дефекты можно объединить.

Основными параметрами обжига, естественно, являются температура и время нахождения в печи, но помимо этого имеется ряд других параметров, всего около 20, степень влияния которых, по-нашему мнению, поможет выделить нейронная сеть.

Как известно, для качественного обучения сети требуется достаточный объем обучающего множества, например, в [5] предлагается формула:

$$Q \gg 7 \cdot N_x + 15, \quad (1)$$

где Q – количество примеров обучающего множества, N_x – количество входных параметров.

Следуя формуле (1), в нашем случае при 40 входных параметрах для создания сети моделирующей подпроцесс прессования стержня, требуется выборка из минимум 295 примеров, а для отжига – минимум 155.

Также следует отметить, что может не получиться выявить закономерности не подразделяя типы брака, и в этом случае, как при прессовании стержня, так и обжиге необходимо иметь достаточное количество примеров с негативным результатом процесса, т.е. полученным браком на выходе по каждому типу определенного закодированного дефекта.

Выбор архитектуры сети, типа используемых в ней нейронов и количества скрытых слоев будет зависеть от полученной выборки. Учитывая процент брака в изготовлении стержней на обоих этапах можно предположить, что нейронная сеть обучится с приемлемой точностью.

Заключение

Несмотря на развитие литейных технологий, к сожалению, проблема большого количества брака отливок лопаток турбины авиационных двигателей, все еще является актуальной.

Наличие опыта ученых в задачах снижения брака и улучшения качества литейных изделий [6-13] дает надежду на то, что данная задача вполне решаема и применение методов искусственного интеллекта позволит определить наиболее влияющие на процесс технологические параметры и за счет их регулировки снизить процент брака.

Библиографический список

1. Испытания, обеспечение надежности и ремонт авиационных двигателей и энергетических установок: Учеб. пособие / Ю.С. Елисеев, В.В. Крымов, К.А. Малиновский, В.Г. Попов, Н.Л. Ярославцев. – М.: Изд-во МАИ, 2005. – 540 с.
2. Завалишин И.В., Финогеев А.Г. Особенности технологической подготовки производства деталей турбины газотурбинного двигателя // Труды МАИ. 2012. № 56. С. 1-11.
3. Миролубова Т.В., Голдобин М.А., Морозов А.А., Ясницкий Л.Н. Современное состояние, возможности и перспективы применения методов искусственного интеллекта для прогнозирования, управления и повышения качества отливок лопаток авиационных двигателей // Сборник: Искусственный интеллект в решении актуальных задач социальных и экономических проблем XXI века, 2019г. С. 167-172.
4. Ясницкий Л.Н. Интеллектуальные системы. Москва, «Лаборатория знаний», 2016. – 176
5. Дайтбегов Д. М. Компьютерные технологии анализа данных в эконометрике, 2008.

6. Самойлович Ю.А., Ясницкий Л.Н. Математическое моделирование затвердевания стали с учетом термоконвективного движения расплава // Известия ВУЗов. Черная металлургия. – 1981. – №12. – С. 75-78.
7. Самойлович Ю.А., Кабаков З.К., Ясницкий Л.Н. Исследование термогравитационной конвекции при затвердевании жидкой стали методом математического моделирования // Инженерно-физический журнал. 1983. №3. С.456-473.
8. Samoilovich, Yu.A., Kabakov, Z.K., Yasnitskii, L.N. Thermogravitation convection of a melt under casting directional solidification conditions // Russian metallurgy. Metally. 1985. (2), с. 88-92
9. Самойлович Ю.А. Фультмахт В.В. Кабаков З.К. Ясницкий Л.Н. Тепловая конвекция жидкой стали при затвердевании непрерывного слитка // Известия АН СССР. Металлы. 1985. №1. С.49-54.
10. Самойлович Ю.А., Ясницкий Л.Н. Неустойчивость тепловой гравитационной конвекции в жидком ядре затвердевающей отливки // Теплофизика высоких температур. – 1982. – Т. XX. – №5. – С. 1002-1004.
11. Самойлович Ю.А., Ясницкий Л.Н. Сопряженная задача теплообмена, гидродинамики и затвердевания расплава // Инженерно-Физический журнал. – 1981. – Т. XLI. – №6. – С. 1109-1118.
12. Долбенко Е.Т., Назаратин В.В., Кабаков З.К., Амелянчик А.В., Ясницкий Л.Н. Анализ тепловых и гидродинамических явлений в процессе кристаллизации отливки в условиях направленного затвердевания // Технология стального литья и литейной формы: Труды ЦНИИТМАШ. №164. М: 1981. С.31-35.
13. Ясницкий Л.Н. Гидродинамическое обоснование рациональных режимов получения стальных слитков. Диссертация на соиск. уч. степени к.т.н. по специальности 05.16.02 – Металлургия черных металлов. Свердловск, 1983.

УДК 004.032.26 796.712 796.71.093.52

ПРОГНОЗИРОВАНИЕ МЕСТА КОМАНДЫ В АВТОГОНОКАХ «ФОРМУЛА 1» С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

Глушкова Елена Максимовна, Иванов Александр Дмитриевич

Пермский государственный национальный исследовательский университет,
КМБ, 614990, Россия, г. Пермь, ул. Букирева 15, helglu@mail.ru,
mr.ivlex@gmail.com

Целью исследования является изучение возможности прогнозирования результатов команд в автогонках Формула 1 с помощью компьютерной программы на базе нейронной сети. В ходе работы была спроектирована и обучена с помощью существующей статистики результатов Формулы 1

нейронная сеть, были проанализированы параметры, влияющие на результаты команд по ходу сезона, определена их значимость. С помощью полученной компьютерной программы возможно формирование полезных рекомендаций для команд Формулы 1.

Ключевые слова: искусственный интеллект, нейронные сети, прогнозирование, автогонки, Формула 1.

Введение. Методы искусственного интеллекта применяются в различных сферах человеческой деятельности. Одним из перспективных направлений является прогнозирование результатов в спорте. Изучение данной области позволит спортсменам выстраивать свою карьеру, спортивным командам – использовать полученные знания для достижения более высоких результатов (например, при помощи изменения состава команды, оптимизации тренировок и пр.). Кроме того, существуют букмекерские конторы, которые зарабатывают деньги на ставках на спорт, а также люди, делающие данные ставки. Данная область привлекательна тем, что по каждому из видов спорта ведется достаточно подробная статистика, существует множество источников исходных данных. Проблемой является наличие огромного количества факторов, влияющих на результат, взаимосвязь между которыми очень сложно установить. Именно здесь находят свое применение нейросети.

Существует несколько работ, посвященных прогнозированию результатов в различных видах спорта. Это, например, прогнозирование результата хоккейных матчей [1], результаты чемпионата по футболу ЕВРО-2016 [2], результаты чемпионата мира по легкой атлетике 2015 [3], состязаний по бегу [4], соревнований по спортивной ходьбе [5], соревнований по плаванию [6] и фигурному катанию [7].

Однако в научных журналах международного уровня практически отсутствуют статьи, посвященные прогнозированию результатов автогонок.

В качестве предметной области была выбрана следующая: прогнозирование места команды Формулы 1 по итогу сезона. Результаты, полученные в ходе работы, могут быть интересны как самим командам Формулы 1, так и людям, занимающимся букмекерством.

Каждый сезон Формулы 1 состоит из определенного количества этапов, их количество, как и количество команд, известны заранее, до начала самого сезона. В каждом этапе от каждой команды участвует два гонщика, допускается изменение состава команды по ходу сезона, но больше двух гонщиков от одной команды одновременно быть не может. Каждый этап состоит из 3-х тренировочных сессий, где команды занимаются поиском настроек автомобилей под конкретные трассы, квалификации, где задача гонщиков – проехать один круг максимально быстро, т.к. данный результат определяет их стартовую позицию в гонке, и самой гонки, по результатам которой гонщики набирают очки в личном чемпионате и команды набирают очки в кубке конструкторов. Количество очков и места, за которые очки начисляют, могут меняться от сезона к сезону в зависимости от регламента,

но главное правило остается одним – чем выше позиция гонщика, тем больше очков он получит. Команда получает за одну гонку столько очков, сколько в сумме заработали два гонщика данной команды.

Методика построения нейросетевой модели. Для построения нейросетевой модели было составлено множество примеров, полученное из открытых источников данных.

В качестве входных параметров были выбраны следующие:

- X1 – сезон (год)
- X2 – номер гонки в сезоне
- X3 – всего гонок в сезоне
- X4 – ID команды
- X5 – кол-во очков команды в текущем сезоне
- X6 – кол-во побед команды в текущем сезоне
- X7 – текущая позиция команды в чемпионате
- X8 – участие команды в прошлом сезоне
- X9 – кол-во очков команды, набранных в прошлом сезоне
- X10 – кол-во побед команд за прошлый сезон
- X11 – место команды в чемпионате по итогу прошлого сезона
- X12 – ID первого пилота
- X13 – кол-во очков первого пилота в текущем сезоне
- X14 – кол-во побед первого пилота в текущем сезоне
- X15 – текущая позиция первого пилота в чемпионате
- X16 – участие первого пилота в прошлом сезоне
- X17 – кол-во очков первого пилота, набранных в прошлом сезоне
- X18 – кол-во побед первого пилота за прошлый сезон
- X19 – место первого пилота в чемпионате по итогу прошлого сезона
- X20 – ID второго пилота
- X21 – кол-во очков второго пилота в текущем сезоне
- X22 – кол-во побед второго пилота в текущем сезоне
- X23 – текущая позиция второго пилота в чемпионате
- X24 – участие второго пилота в прошлом сезоне
- X25 – кол-во очков второго пилота, набранных в прошлом сезоне
- X26 – кол-во побед второго пилота за прошлый сезон
- X27 – место второго пилота в чемпионате по итогу прошлого сезона
- X28 – всего команд в текущем сезоне
- X29 – всего команд в прошлом сезоне
- X30 – всего пилотов в текущем сезоне
- X31 – всего пилотов в прошлом сезоне

Если команда не участвовала в прошлом сезоне, за количество побед за прошлый сезон берется 0, за ее место – количество команд в прошлом сезоне + 1. Аналогично с пилотами.

Выходным параметром Y является место команды, которое займет команда по итогу сезона в автогонках Формула 1.

Множество примеров, состоящее из 4675 записей, было поделено на обучающее, предназначенное для обучения нейронной сети, и тестовое,

предназначенное для проверки нейронной сети, множества. В тестовое множество вошло 15% от общего числа примеров, т.е. 701 запись. Количество примеров обучающего множества удовлетворяет требованию репрезентативности: оно значительно больше, чем $7N_x + 15$, где N_x – число входных параметров.

На следующем этапе была спроектирована нейронная сеть. Проектирование нейронной сети выполнялось с помощью Нейросимулятора Nsim [8]. Число нейронов на входном слое – 31 (по числу входных параметров), на выходном – 1 нейрон, соответствующий прогнозируемому значению – месту команды в гонке. Также в проектируемой нейронной сети имеется один скрытый слой с 31 нейроном. Для определения числа нейронов на скрытом слое необходимо воспользоваться формулой, являющейся следствием теорем Арнольда – Колмогорова – Хехт-Нильсена:

$$\frac{N_y Q}{1 + (Q)} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y,$$

где N_y – размерность выходного сигнала; Q – число элементов обучающей выборки; N_w – необходимое число синаптических весов; N_x – размерность входного сигнала. Оценив с помощью этой формулы необходимое число синаптических весов, можно рассчитать число нейронов в скрытых слоях. Например, число нейронов скрытого слоя двухслойного персептрона будет равно

$$N = \frac{N_w}{N_x + N_y}.$$

Для проектируемой нейронной сети необходимое число синаптических весов лежит в диапазоне $355 \leq N_w \leq 5010$, а число нейронов на скрытом слое – в диапазоне $12 \leq N \leq 156$.

После проектирования нейронной сети переходим к ее обучению. Спроектированная нейронная сеть была обучена на 3974 примерах обучающего множества.

Результаты компьютерных экспериментов. Результат тестирования сети, выполненный на 701 тестовых примерах, представлен на рисунке 2 (для наглядности на рисунке представлены 50 из 701 примеров). Из данного рисунка видно, что место команды в гонке, оцененное с помощью нейронной сети, незначительно отличается от действительного места команды. Т.е. спроектированная нейросетевая математическая модель адекватна предметной области.




Рисунок 1. Пример тестирования сети: сопоставление действительного и оцененного с помощью нейросети места команды в гонке

Таким образом, нейронная сеть была проверена на тестовых примерах и была доказана адекватность нейросетевой математической модели. После этого мы можем приступать к ее исследованию и прогнозированию.

Выясним степень влияния входных параметров модели на результат моделирования – место команды в гонке. Для этого будем по очереди исключать входные параметры и наблюдать за погрешностью тестирования. Чем выше погрешность тестирования, тем значимее исключенный входной параметр. На рисунке 3 представлена гистограмма значимости входных параметров, полученная методом поочередного исключения входных параметров [9]. По вертикальной оси в процентах указана значимость входных параметров. При этом, сумма значений высот столбцов составляет 100%.




Рисунок 2. Значимость входных параметров, вычисленная с помощью нейронной сети

На полученной гистограмме видно, что наиболее значимыми являются следующие параметры:

- Место команды в чемпионате по итогу прошлого сезона – 12,3%
- Текущая позиция команды в чемпионате – 7,3%
- Всего пилотов в текущем сезоне – 6,5%
- Участие команды в прошлом сезоне – 5,8%
- Место второго пилота в чемпионате по итогу прошлого сезона – 5,7%
- Место первого пилота в чемпионате по итогу прошлого сезона – 5,7%
- Участие первого пилота в прошлом сезоне – 5,5%

Полученная нейросетевая математическая модель адекватна моделируемой предметной области, и поэтому ее можно использовать для изучения закономерностей распределения команд по местам в автогонке. Для изучения таких закономерностей можно изменять один входной параметр и наблюдать за результатами вычислений.

По результату сезона 2016 года команда Red Bull заняла 2 место. За нее выступали гонщики Даниэль Риккардо и Даниил Квят. Пронаблюдаем с помощью полученной модели, как изменился бы итоговый результат команды по итогу сезона, если бы вместо Даниила Квята за команду выступал другой пилот.




Рисунок 3. Зависимость места команды Red Bull по итогу сезона от второго пилота. Соответствие номера и пилота: 1 – Даниил Квят; 2 – Нико Росберг; 3 – Льюис Хэмилтон; 4 – Рио Харьянто; 5 – Карлос Сайнс; 6 – Эстебан Гутьеррес

Как видно из рисунка 4, команда Red Bull заняла бы 4 место, если бы вторым пилотом был Карлос Сайнс или Эстебан Гутьеррес и 3 место, если бы напарником Даниэля Риккардо стал Льюис Хэмилтон или Нико Росберг. Согласно прогнозам построенной модели, команда Red Bull приняла наиболее оптимальное решение, взяв в свой состав Даниила Квята в качестве второго пилота.

Закключение. Таким образом, в данной работе была предложена методика прогнозирования места команды в автогонках Формула 1. Была получена и исследована нейросетевая математическая модель, соответствующая предметной области. Показано, что с помощью разработанной модели можно формировать полезные для спортивных команд рекомендации.

Библиографический список

1. Крутиков А.К. Прогнозирование результата хоккейного матча с использованием специализированного программного модуля на основе искусственной нейронной сети // Научное обозрение. Технические науки. № 2. 2019. С. 19-22.
2. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по футболу Евро-

- 2016 методом нейросетевого моделирования // Вестник спортивной науки. № 5. 2015. С. 15-20.
3. Л. Н. Ясницкий, А. В. Киросова, А. В. Ратегова. Методика нейросетевого прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Математика. Механика. Информатика. № 3(26). 2014. С. 90-97.
 4. Przednowek K, Iskra J, Maszczyk A, Nawrocka M. Regression shrinkage and neural models in predicting the results of 400-metres hurdles races. *Biol Sport*, no. 33(4), pp. 415–421, 2016.
 5. K. Przednowek and K. Wiktorowicz. Prediction of the result in race walking using regularized regression models. *Journal of Theoretical and Applied Computer Science*, vol. 7, no. 2, pp. 45- 58, 2013.
 6. A. Maszczyk, R. Rocznio, Z. Wa'skiewicz et al., "Application of regression and neural models to predict competitive swimming performance," *Perceptual and Motor Skills*, vol. 114, no. 2, pp. 610–626, 2012.
 7. Ясницкий Д.Н., Внукова О.В. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта. *Современные проблемы науки и образования*. 2014. № 1. С. 189.
 8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
 9. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005 176 с.

FORECASTING THE FORMULA 1 CAR RACE RESULTS BY NEURAL NETWORKS

Glushkova Elena M., Ivanov Alexander D.

Perm State University

614990, Russia, Perm, street Bukireva, 15, helglu@mail.ru, mr.ivlex@gmail.com

The aim of the study is to investigate the possibility of predicting the results of teams in Formula 1 car races using a computer program based on a neural network. A neural network was designed and trained using the existing statistics of the results of Formula 1, the parameters affecting the results of teams during the season were analyzed, their significance was determined. Using the resulting computer program, it is possible to form useful recommendations for Formula 1 teams.

Key words: artificial intelligence, neural networks, forecasting, auto racing, Formula

ПРОГНОЗИРОВАНИЕ РЕЗУЛЬТАТОВ АВТОГОНОК «ФОРМУЛА 1» С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

Глушкова Елена Максимовна, Иванов Александр Дмитриевич

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева 15, helglu@mail.ru,
mr.ivlex@gmail.com

Целью исследования является изучение возможности прогнозирования результатов команд в автогонках Формула 1 с помощью компьютерной программы на базе нейронной сети. В ходе работы была спроектирована и обучена с помощью существующей статистики результатов Формулы 1 нейронная сеть, были проанализированы параметры, влияющие на результаты команд по ходу сезона, определена их значимость. С помощью полученной компьютерной программы возможно формирование полезных рекомендаций для команд Формулы 1.

Ключевые слова: искусственный интеллект, нейронные сети, прогнозирование, автогонки, Формула 1.

Введение. Методы искусственного интеллекта применяются в различных сферах человеческой деятельности. Одним из перспективных направлений является прогнозирование результатов в спорте. Изучение данной области позволит спортсменам выстраивать свою карьеру, спортивным командам – использовать полученные знания для достижения более высоких результатов (например, при помощи изменения состава команды, оптимизации тренировок и пр.). Кроме того, существуют букмекерские конторы, которые зарабатывают деньги на ставках на спорт, а также люди, делающие данные ставки. Данная область привлекательна тем, что по каждому из видов спорта ведется достаточно подробная статистика, существует множество источников исходных данных. Проблемой является наличие огромного количества факторов, влияющих на результат, взаимосвязь между которыми очень сложно установить. Именно здесь находят свое применение нейросети.

Существует несколько работ, посвященных прогнозированию результатов в различных видах спорта. Это, например, прогнозирование результата хоккейных матчей [1], результаты чемпионата по футболу ЕВРО-2016 [2], результаты чемпионата мира по легкой атлетике 2015 [3], состязаний по бегу [4], соревнований по спортивной ходьбе [5], соревнований по плаванию [6] и фигурному катанию [7].

Однако в научных журналах международного уровня практически отсутствуют статьи, посвященные прогнозированию результатов автогонок.

В качестве предметной области была выбрана следующая: прогнозирование места команды Формулы 1 по итогу сезона. Результаты, полученные в ходе работы, могут быть интересны как самим командам Формулы 1, так и людям, занимающимся букмекерством.

Каждый сезон Формулы один состоит из определенного количества этапов – гран-при, их количество, как и количество команд, известны заранее, до начала самого сезона. В каждом этапе от каждой команды участвует два гонщика, допускается изменение состава команды по ходу сезона, но больше двух гонщиков от одной команды одновременно быть не может. Каждый этап состоит из 3-х тренировочных сессий, где команды занимаются поиском настроек автомобилей под конкретные трассы, квалификации, где задача гонщиков – проехать один круг максимально быстро, т.к. данный результат определяет их стартовую позицию в гонке, и самой гонки, по результатам которой гонщики набирают очки в личном чемпионате и команды набирают очки в кубке конструкторов. Количество очков и места, за которые очки начисляют, могут меняться от сезона к сезону в зависимости от регламента, но главное правило остается одним – чем выше позиция гонщика, тем больше очков он получит. Команда получает за одну гонку столько очков, сколько в сумме заработали два гонщика данной команды.

Методика

Для построения нейросетевой модели было составлено множество примеров, полученное из открытых источников данных.

В качестве входных параметров были выбраны следующие:

X1 – сезон (год)

X2 – ID гран-при в сезоне

X3 – ID трассы

X4 – номер гран-при в сезоне

X5 – всего гран-при в сезоне

X6 – ID пилота

X7 – национальность пилота

X8 – текущая позиция пилота в чемпионате

X9 – кол-во побед пилота в текущем сезоне

X10 – кол-во очков пилота в текущем сезоне

X11 – результат пилота на этой же трассе в прошлом сезоне

X12 – результат пилота в прошлом гран-при

X13 – результат пилота в позапрошлом гран-при

X14 – возраст пилота

X15 – результат пилота в квалификации

X16 – ID команды

X17 – текущая позиция команды в чемпионате

X18 – кол-во побед команды в текущем сезоне

X19 – кол-во очков команды в текущем сезоне

X20 – кол-во сходов пилотов команды в текущем сезоне

X21 – место команды по итогу прошлого сезона

X22 – место команды по итогу позапрошлого сезона

X23 – всего пилотов участвует в сезоне

Если команда не участвовала в прошлом сезоне, за количество ее очков и побед за прошлый сезон берется 0, за ее место – количество команд в прошлом сезоне + 1. Аналогично с пилотами.

Выходным параметром Y является место пилота, которое он займет по итогу сезона в автогонках Формула 1.

Множество примеров, состоящее из 7527 записей, было поделено на обучающее, предназначенное для обучения нейронной сети, и тестовое, предназначенное для проверки нейронной сети, множества. В тестовое множество вошло примерно 10% от общего числа примеров, т.е. 800 записей. Количество примеров обучающего множества удовлетворяет требованию репрезентативности: оно значительно больше, чем $7N_x + 15$, где N_x – число входных параметров.

На следующем этапе была спроектирована нейронная сеть. Проектирование нейронной сети выполнялось с помощью Нейросимулятора Nsim [8]. Число нейронов на входном слое – 23 (по числу входных параметров), на выходном – 1 нейрон, соответствующий прогнозируемому значению – месту команды в гонке. Также в проектируемой нейронной сети имеется один скрытый слой с 23 нейронами. Для определения числа нейронов на скрытом слое необходимо воспользоваться формулой, являющейся следствием теорем Арнольда – Колмогорова – Хехт-Нильсена:

$$\frac{N_y Q}{1 + \log_2(Q)} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y,$$

где N_y – размерность выходного сигнала; Q – число элементов обучающей выборки; N_w – необходимое число синаптических весов; N_x – размерность входного сигнала. Оценив с помощью этой формулы необходимое число синаптических весов, можно рассчитать число нейронов в скрытых слоях. Например, число нейронов скрытого слоя двухслойного персептрона будет равно

$$N = \frac{N_w}{N_x + N_y}.$$

Для проектируемой нейронной сети необходимое число синаптических весов лежит в диапазоне $542 \leq N_w \leq 8207$, а число нейронов на скрытом слое – в диапазоне $22 \leq N \leq 342$.

После проектирования нейронной сети переходим к ее обучению. Спроектированная нейронная сеть была обучена на 6727 примерах обучающего множества.

Результаты компьютерных экспериментов. Результат тестирования сети, выполненный на 800 тестовых примерах, представлен на рисунке 2 (для наглядности на рисунке представлены 50 из 800 примеров). Из данного рисунка видно, что место команды в гонке, оцененное с помощью нейронной сети, незначительно отличается от действительного места команды. Т.е.

спроектированная нейросетевая математическая модель адекватна предметной области.




Рис. 1. Пример тестирования сети: сопоставление действительного и оцененного с помощью нейросети места пилота по итогу сезона

Таким образом, нейронная сеть была проверена на тестовых примерах и была доказана адекватность нейросетевой математической модели. После этого мы можем приступить к ее исследованию и прогнозированию.

Выясним степень влияния входных параметров модели на результат моделирования – место команды в гонке. Для этого будем по очереди исключать входные параметры и наблюдать за погрешностью тестирования. Чем выше погрешность тестирования, тем значимее исключенный входной параметр. На рисунке 3 представлена гистограмма значимости входных параметров, полученная методом поочередного исключения входных параметров [9]. Во вертикальной оси в процентах указана значимость входных параметров. При этом, сумма значений высот столбцов составляет 100%.




Рис. 2. Значимость входных параметров, вычисленная с помощью нейронной сети

На полученной гистограмме видно, что наиболее значимыми являются следующие параметры:

- ID пилота – 27,14%
- Сезон (год) – 12,3%
- ID трассы – 9,7%
- ID команды – 7%
- Место команды по итогу прошлого сезона – 6,9%
- Всего гран-при в сезоне – 5,3%
- Всего пилотов участвует в сезоне – 4,75%

Полученная нейросетевая математическая модель адекватна моделируемой

предметной области, и поэтому ее можно использовать для изучения закономерностей распределения команд по местам в автогонке. Для изучения таких закономерностей можно изменять один входной параметр и наблюдать за результатами вычислений.

Фернандо Алонсо завершил свою карьеру в Формуле 1 в 2018 году в возрасте 37 лет. Пронаблюдаем с помощью построенной модели, как изменились бы его результаты, если бы он продолжил выступать в Формуле 1.




Рис. 3. Зависимость места Фернандо Алонсо по итогу сезона от его возраста

Мы видим, что если бы Алонсо остался в Формуле 1, то его результаты улучшались бы еще на протяжении двух лет, а затем пошли на спад, соответственно, согласно построенной модели можно сказать, что Алонсо достаточно своевременно завершил свою карьеру в Формуле 1.

Заключение. Таким образом, в данной работе была предложена методика прогнозирования места команды в автогонках Формула 1. Была получена и исследована нейросетевая математическая модель, соответствующая предметной области. Показано, что с помощью разработанной модели можно формировать полезные для спортивных команд рекомендации.

Библиографический список

1. Крутиков А.К. Прогнозирование результата хоккейного матча с использованием специализированного программного модуля на основе искусственной нейронной сети // Научное обозрение. Технические науки. № 2. 2019. С. 19-22.
2. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по футболу Евро-

- 2016 методом нейросетевого моделирования // Вестник спортивной науки. № 5. 2015. С. 15-20.
3. Л. Н. Ясницкий, А. В. Киросова, А. В. Ратегова. Методика нейросетевого прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Математика. Механика. Информатика. № 3(26). 2014. С. 90-97.
 4. Przednowek K, Iskra J, Maszczyk A, Nawrocka M. Regression shrinkage and neural models in predicting the results of 400-metres hurdles races. *Biol Sport*, no. 33(4), pp. 415–421, 2016.
 5. K. Przednowek and K. Wiktorowicz. Prediction of the result in race walking using regularized regression models. *Journal of Theoretical and Applied Computer Science*, vol. 7, no. 2, pp. 45- 58, 2013.
 6. A. Maszczyk, R. Rocznio, Z. Wa'skiewicz et al., "Application of regression and neural models to predict competitive swimming performance," *Perceptual and Motor Skills*, vol. 114, no. 2, pp. 610–626, 2012.
 7. Ясницкий Д.Н., Внукова О.В. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта. *Современные проблемы науки и образования*. 2014. № 1. С. 189.
 8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
 9. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005 176 с.

FORECASTING THE FORMULA 1 CAR RACE RESULTS BY NEURAL NETWORKS

Glushkova Elena M., Ivanov Alexander D.

Perm State University

614990, Russia, Perm, street Bukireva, 15, helglu@mail.ru

The aim of the study is to investigate the possibility of predicting the results of teams in Formula 1 car races using a computer program based on a neural network. A neural network was designed and trained using the existing statistics of the results of Formula 1, the parameters affecting the results of teams during the season were analyzed, their significance was determined. Using the resulting computer program, it is possible to form useful recommendations for Formula 1 teams.

Key words: artificial intelligence, neural networks, forecasting, auto racing, Formula

УСОВЕРШЕНСТВОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В UNITY

Копелиович Дмитрий Игоревич, Кондратенко Роман Викторович
Брянский государственный технический университет, Россия, г. Брянск,
Институтская ул. 16, roman_kondratenko@bk.ru

Проведён анализ существующего искусственного интеллекта в unity, выявлены его основные преимущества и недостатки. На основе существующего ИИ разработаны усовершенствованные модификации, позволяющие упростить и расширить функциональность искусственного интеллекта в целом.

Ключевые слова: виртуальные тренажёры, симуляторы, ИИ, искусственный интеллект, виртуальная реальность, NPC, unity.

Введение: существует несколько определений искусственного интеллекта, одно из них говорит о том, что ИИ – способность цифрового компьютера или управляемого компьютером робота выполнять задачи, обычно связанные с разумными существами. [1, С. 150-155]. Сфера же применения искусственного интеллекта очень обширна. В каждом виртуальном приложении необходим взаимодействующий с пользователем искусственный интеллект, чаще всего в виде вспомогательных элементов. В некоторых случаях ИИ должен мешать пользователю, в других – помогать ему, но у всех производимых компьютером действий существует некоторое сходство. В зависимости от требований проекта, ИИ может использовать простые или сложные поведения. Такими требованиями могут быть умные подсказки в зависимости от ситуации или различного рода действия в виртуальном мире.

Стоит отметить, что количество различных системных приложений постоянно растёт. [1, С. 232-235]. Следовательно, необходимо сделать так, чтобы и качество ИИ возрастало, но это не всегда так. Особенно остро эта проблема прослеживается при использовании интеллектуальных возможностей в Unity, которые представлены в виде навигационной сетки. Несмотря на то, что ИИ на данной платформе появился не так давно, но уже на протяжении 3х лет его основные возможности никак не менялись и не совершенствовались. К основным возможностям относятся низкоуровневые настройки, такие как скорость, угол поворота NPC, расстояние для остановки и т.д. В данной системе отсутствуют высокоуровневые настройки, которые связаны с графической настройкой последовательности действий, а также с принятием решения, которое подразумевает под собой выбор определённых действий в зависимости от ситуации.

Особенности искусственного интеллекта в Unity: Межплатформенная среда для разработки, Unity 2019.3.9 предоставляет разработчику настраиваемую навигационную систему. Данная система позволяет создавать виртуальных персонажей, которые могут разумно перемещаться по игровому миру, используя навигационные сетки, которые автоматически создаются из геометрии сцены. Динамические препятствия, создаваемые пользователем, позволяют изменять навигацию персонажей во время выполнения, в то время как ссылки вне сетки позволяют создавать определенные действия, такие как открытие дверей или спрыгивание с выступа. На рис. 1 показана схема взаимодействия всех компонентов, которые относятся к искусственному интеллекту Unity.

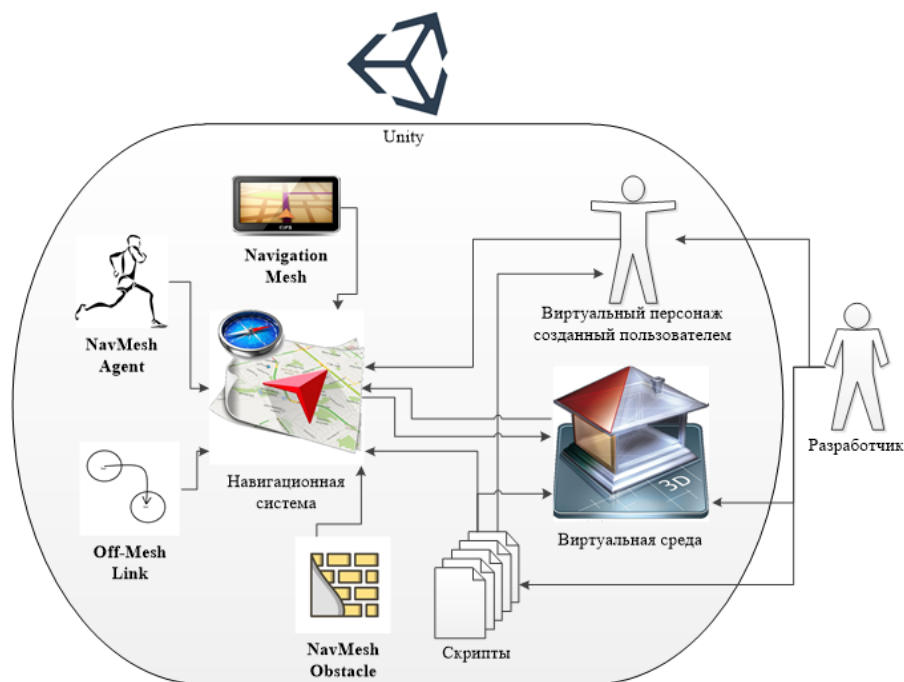


Рисунок 1. Схема взаимодействия разработчика со встроенным ИИ

NavMesh (сокращенно от Navigation Mesh) – это структура данных, которая описывает проходимые поверхности игрового мира и позволяет найти путь из одного проходимого места в другое в игровом мире [3, С. 102-109]. Структура данных строится, или выпекается, автоматически из геометрии, которая была создана пользователем. На рис. 2 представлено визуальное отображение навигационной сетки (NavMesh).




Рис. 2 Навигационная сетка

Компонент NavMesh Agent помогает создать виртуальных персонажей, которые избегают друг друга при движении к своей цели [2, С. 55-59]. Агенты рассуждают об игровом мире с помощью навигационной маски, и они знают, как избегать друг друга, а также движущихся препятствий.

Компонент Off-Mesh Link позволяет включать навигационные ярлыки, которые не могут быть представлены с помощью проходимой поверхности. Например, перепрыгивая через канаву или забор, или открывая дверь перед тем, как пройти через нее, можно все описать как звенья вне сетки.

Компонент NavMeshObstacle, позволяет описать движущиеся препятствия, которые агенты должны избегать во время навигации по миру. Бочка или ящик, управляемые физической системой, являются хорошим примером препятствия. В то время как препятствие движется агенты делают все возможное, чтобы избежать его, но как только препятствие становится неподвижным, оно вырезает отверстие в NavMesh, чтобы агенты могли изменить свои пути, чтобы обойти его, или если неподвижное препятствие блокирует путь или пути, агенты могут найти другой маршрут.

Таким образом, если обобщить всё выше сказанное, то можно сделать вывод о том, что unity предоставляет удобную, визуально наглядную, навигационную сетку для виртуальных персонажей, т.е. разработчик может настроить сетку, установить препятствия, задать какие-то обходные пути и на этом возможности визуальной настройки заканчиваются, и после всех этих действий приходится приступать к программированию, а именно программно описывать куда должен идти виртуальный персонаж, как должен идти, какую анимацию должен включить, какую выключить.

Особенности разработанных усовершенствований ИИ: разработанные усовершенствования, позволяют исключить модуль «Скрипты», представленный на рисунке 1, который подразумевал под собой написание логики перемещения, включение и отключение анимации и многое другое, заменив его на разработанные визуально настраиваемые модификации, иначе говоря, пользователю больше не потребуется писать тонны кода, достаточно просто выставить в визуальном редакторе необходимые настройки (Рис 3). Также, данные модификации предоставляют искусственному интеллекту

возможность выбора определённой последовательности действий. На вершине всех разработанных модификаций стоит список работ, их можно создавать любое количество, данный список называется ListWork, он необходим для упрощения структуры и для включения определённого типа работы в зависимости от ситуации, например, для NPS доступно несколько работ: заварить чай, починить автомобиль. ИИ будет производить выбор между этими работами и выполнять их. Под выполнением подразумевается проигрывание заранее заданных анимаций, подробно установка анимаций рассмотрена ниже.

После составления списка work, для каждой работы необходимо установить, будет ли она проигрываться данным NPS(Play) и может ли данное действие повторяться подряд неограниченное количество раз(Loop). Отсутствие параметра заикливания на всех существующих работах, говорит о том, что виртуальный персонаж перейдёт в пассивное состояние после выполнения всех действий, т.е. будет стоять и ничего не делать.

Далее следует список всех анимаций, которые создаются пользователем, устанавливаемые параметры представлены на рисунке 4.

Comment является необязательным параметром и служит только лишь для присваивания названия данной анимации при необходимости.

IsMove отвечает за передвижение персонажа, если необходимо выполнить лишь передвижение от места до места, то этот параметр необходимо перевести в положение true, при достижении целевой точки(TargetPoint) NPS перейдёт в состояние покоя и начнёт проигрывать следующую анимацию.

Speed это скорость передвижения персонажа.

Блок Animation отвечает за анимацию, которая была создана в AnimationController.

Angle позволяет повернуть неигрового персонажа в указанную позицию.

Fix позволяет прикрепить любые предметы в любое указанное место.

Expect необходимо для анимаций, которые подразумевают коллективное действие, например, перетаскивание двумя NPS тяжёлых предметов, если один из напарников где-то потерялся, то благодаря данному механизму неигровой персонаж в одиночку не будет приступать к тяжёлой работе один.

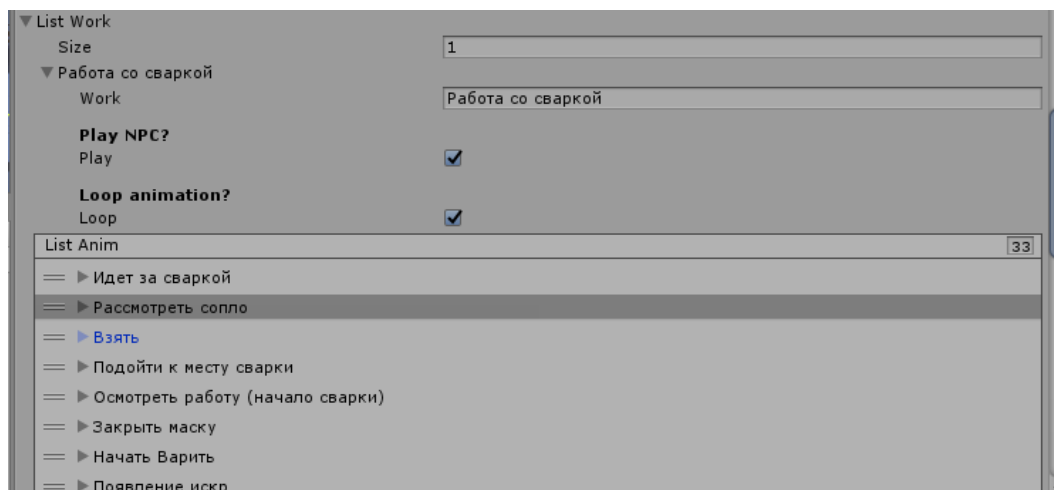


Рис. 3 Визуальное оформление модернизаций ИИ

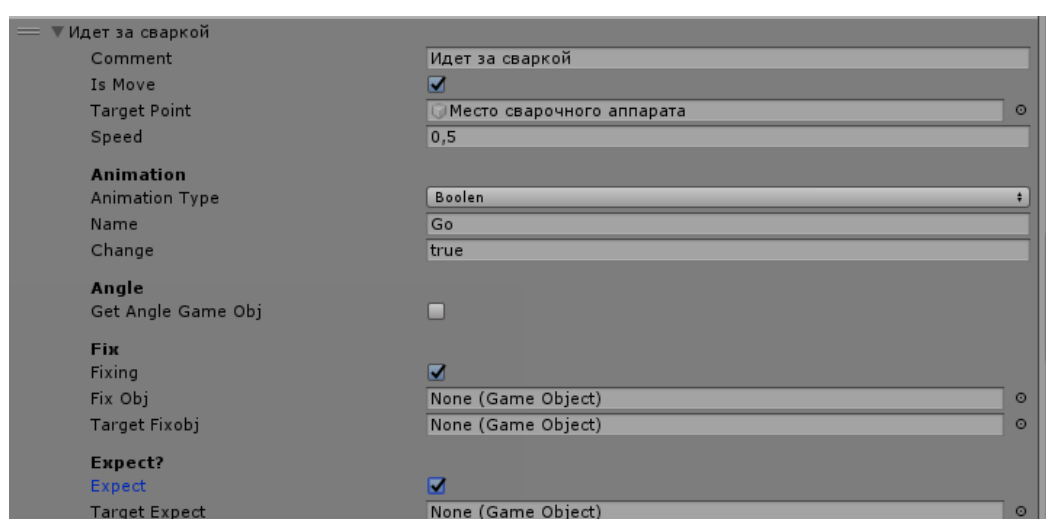


Рис. 4 Визуальное оформление параметров анимации

Заключение: в результате данные модификации позволяют облегчить процесс разработки любого проекта, таким образом, от разработчика уже не требуется программировать логику перемещений, можно просто установить определённые параметры в гибком и визуально приятном интерфейсе и перейти к другим этапам разработки.

Библиографический список

1. Safonov A.L. Multilevel functional-logic models in 3d-simulators of electrical equipment/Safonov A.L., Kopeliovich D.I.//graphicon 2019 – proceedings of the 29th international conference on computer graphics and vision: 23-26 september 2019 y., Bryansk / CEUR Workshop Proceedings, 2019. – pp. 232–235.
2. Искусственный интеллект в управлении человеческими ресурсами/ А.А. Шкунова, М.П. Прохорова, М.А. Зорков, Д.С. Маркова, М.И. Савинов// Инновационная экономика: перспективы развития и совершенствования. – 2020. – 1(43). – 150-155с.

3. Удалов А.Д. Использование compute shader для навигации ИИ-агентов с применением unity/ А.Д. Удалов, А.Н. Архипов, А.В. Панов// Передовые инновационные разработки. перспективы и опыт использования, проблемы внедрения в производство. . – 2019. – 3. – 55-59с.
4. Внедрение искусственного интеллекта в игровые приложения/ В.С. Гридчин, Я.В. Орехов, В.А. Балаев, Е.И. Николаев // Студенческая наука для развития информационного общества: материалы конф. – Ставрополь. – 2019. – 102-109с.

IMPROVING ARTIFICIAL INTELLIGENCE IN UNITY

*Kopeliovich Dmitry I., Safonov Alexander L.,
Kondratenko Roman V.*

Bryansk state technical University, 16 Institutskaya str., Bryansk, Russia
roman_kondratenko@bk.ru

The analysis of the existing artificial intelligence in unity is carried out, its main advantages and disadvantages are revealed. Based on the existing AI, improved modifications have been developed to simplify and expand the functionality of artificial intelligence in General.

Key words: virtual simulators, simulators, AI, artificial intelligence, virtual reality, NPC, unity.

УДК 004.85

ПРОГНОЗИРОВАНИЕ КОНЦЕНТРАЦИИ МЕТАНА В РАБОЧЕЙ ЗОНЕ УГОЛЬНОЙ ШАХТЫ НА ОСНОВЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

Бузмаков Дмитрий Михайлович

Пермский государственный национальный исследовательский университет,
ПМИ. Россия, г. Пермь, 614990, ул. Букирева, 15,
dima27011999@yandex.ru

Данная работа описывает модель прогноза содержания метана в атмосфере рабочей зоны угольной шахты. Рассмотрены конкретные предприятия, а именно шахты по добыче угля. Самым опасным фактором при добыче угля является выделение метана. Изменение данного параметра необходимо прогнозировать для того, чтобы максимизировать объем добытого угля и минимизировать риск аварии.

Ключевые слова: искусственный интеллект; метан; угольная шахта; рекуррентная нейронная сеть; прогнозирование временных рядов.

Введение

Прогнозирование временных рядов довольно частая тема научных статей, многие авторы представляют свои исследования по данной тематике, однако на сегодняшний день успешные модели прогнозирования опираются на регрессионный анализ данных и на так называемый «метод скользящих окон». Однако данные модели работают стабильно и с большой точностью лишь в тех случаях, когда имеются данные о всех факторах, которые оказывают непосредственное влияние на изучаемую величину. К сожалению, на реальном производстве не всегда можно измерить нужные данные. В настоящей работе рассматривается случай, когда мы имеем данные лишь о косвенных признаках, которые влияют на концентрацию метана в атмосфере рабочей зоны угольной шахты.

Выбор модели нейронной сети

Существует большое количество различных моделей нейронных сетей: однослойный и многослойный перцептрон, свёрточные нейронные сети и многие другие. В качестве рабочей модели была выбрана рекуррентная нейронная сеть, так как рекуррентные нейронные сети имеют свойство оценивать предыдущие полученные значения, для получения новых значений. Оценивая временные ряды не сложно понять, что на значения, в определённый момент времени влияют не только входные параметры, полученные на данный момент, но и параметры, которые были получены несколько временных промежутков ранее. Особенно это важно при прогнозе выделения метана из горных пород, поскольку он выделяется не только в месте работы комбайна, но и на всем обнажении пласта.

Учитывая то, что данные были получены в разряженном виде, а также все из них были не нормализованы, обработке данных было отведено большое значение. С помощью регрессионного анализа различные доступные параметры были исследованы на предмет влияния их на контрольное содержание метана. После чего были выделены следующие ведущие показатели:

- средняя сила тока, подаваемая на режущие органы комбайна;
- мощность, потребляемая лавным конвейером;
- расход воздуха, зафиксированный на всех датчиках дегазационных установок;
- расход воздуха, зафиксированный на датчике перед комбайном;
- содержание метана, зафиксированное на датчике перед комбайном.

После этого данные были нормализованы, профильтрованы и преобразованы к нужному виду для подачи на вход рекуррентной нейронной сети.

Вся разработка модели происходила с помощью стандартных возможностей открытой нейросетевой библиотеки Keras. Модель нейронной сети представляла из себя входной слой, скрытый рекуррентный слой Simple RNN, и один выходной слой. Simple RNN – простой слой рекуррентной сети,

который способен предсказывать значение, основываясь лишь на нескольких непосредственно предыдущих данных. Активационной функцией везде выступал гиперболический тангенс. Самые лучшие результаты были получены при анализе 15 предыдущих минут для текущего значения. Результат обучения нейронной сети представлен на рисунке 1.




Рисунок 1 – Графики реального содержания метана (красный) и предсказанного RNN значения на основе пятнадцати предыдущих данных (синий)

В результате получившаяся модель оценивает значение метана с точностью 67%. Данная модель имеет множество различных вариантов доработки. При увеличении интервала обучения, точность модели уменьшается. Это связано в большей степени с тем, что исходные данные имеют некоторые интервалы отсутствующих значений. Неполнота данных может быть связана с различными рода проблемами на производстве. Поэтому интервал для обучения был выбран с наибольшим количеством имеющихся значений. Также для нахождения минимума функции и избегания попадания в локальные экстремумы был применён приём случайных весов нейронов, для нахождения самых благоприятных начальных значений, что привело к необходимости несколько раз обучать нейронную сеть в ожидании наилучшего результата. В итоге нейронная сеть дала точность: 70%. Результаты представлены на рисунке 2.




Рисунок 2 – Графики реального содержания метана (красный) и предсказанного RNN значения (синий) с использованием случайной инициализации нейронов

Если сравнить данный график с предыдущим, то можно заметить, что многие из пиков не совсем точно совпадают.

Также в качестве эксперимента для сравнения была построена глубокая нейронная сеть с рекуррентным слоем и стандартным слоем активации. Результат представлен на рисунке 3.




Рисунок 3 – Графики реального содержания метана (красный) и предсказанного RNN значения (синий) с использованием глубокой нейронной сети

Глубокие нейронные сети достаточно непредсказуемо себя ведут, поэтому они подходят для определённого круга задач. Как видно из графика, эксперимент привел к ухудшению точности модели, поэтому использование глубоких нейронных сетей для данной задачи было отклонено.

Также проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью были выполнены с помощью нейропакета «Нейросимулятор 5.0» [2]. В данной модели был применён метод «скользящих окон». Результат представлен на рисунке 4.




Рисунок 4 – Графики реального содержания метана (красный) и предсказанного значения (синий) с использованием нейросимулятора

Как видно, обучение прошло успешно. Результат получился удачнее, чем с помощью библиотеки Keras. Таким образом, обученная модель в нейросимуляторе 5.0 с использованием метода «скользящих окон», оказалась самой успешной. Её точность составляет 75%.

Стоит отметить, что увеличение слоёв, не улучшило обучение, но усложнило настройку сети.

4. Заключение

Таким образом, самый лучший результат был получен с помощью нейронной сети с одним скрытым слоем и использованием метода «скользящих окон». Такая модель дала результат лучше, чем рекуррентная нейронная сеть и значительно лучше, чем глубокая нейронная сеть.

Поэтому для предсказания временных рядов было решено использовать именно её.

В вопросе сравнения, нейросимулятор 5.0 значительно лучше, чем стандартные методы библиотеки Keras, но к сожалению, он имеет ограниченное количество используемых слоёв (отсутствуют рекуррентные слои, свёрточные слои и другие).

Библиографический список

1. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
2. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
3. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
4. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь: Пермский университет, 2007. 271с.
5. Журавлев Е.И. Разработка геоинформационной системы прогнозирования динамических проявлений в углевмещающем массиве при подземной разработке угольных месторождений

[Электронный ресурс] URL: <https://misis.ru/files/3494/zuravlev-disser.pdf>(дата обращения: 30.03.2020).

6. Николаенко С., Кадурич А., Архангельская Е.. Глубокое обучение. Погружение в мир нейронных сетей. СПб: Питер, 2018.
7. Садовникова Н.А., Шмойлова Р.А. Анализ временных рядов и прогнозирование. ред. Издательский дом Университета "Синергия", 2016.
8. Бендерская Е.Н., Никитин К.В. Рекуррентная нейронная сеть как динамическая система и подходы к ее обучению. Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика, телекоммуникации и управление, 2013.

PREDICTION OF METHANE CONCENTRATION IN THE WORKING AREA OF COAL MINES BASED ON RECURRENT NEURAL NETWORK

Buzmakov Dmitriy M.

Perm State National Research University, 614990, Russia, Perm, street Bukireva, 15, dima27011999@yandex.ru

This article describes a model for predicting the methane content in the atmosphere of a coal mine's working area. Concrete enterprises, namely coal mines, are considered. The most dangerous factor in coal mining is the release of methane. A change in this parameter must be predicted in order to maximize the volume of coal mined and minimize the risk of an accident.

Keywords: AI; methane; coal mine; recurrent neural network; time-series prediction.

УДК 004.891.3

МЕТОДЫ И МОДЕЛИ ФОРМИРОВАНИЯ ДЕСКРИПТОРОВ ДЛЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ ОЦЕНКИ РИСКА ИНФЕКЦИОННЫХ ЗАБОЛЕВАНИЙ НА ОСНОВЕ АНАЛИЗА БИОИМПЕДАНСА ЗОН АНОМАЛЬНОЙ ЭЛЕКТРОПРОВОДНОСТИ

*Мирошников Андрей Валерьевич, Протасова Зейнаб Усама,
Шаталова Ольга Владимировна*

Юго-Западный государственный университет,
305040, Россия, г. Курск, ул. 50 лет Октября, 94, Shatolg@mail.ru

В статье представлено исследование динамических характеристик биоимпеданса в зонах аномальной электропроводности, на основе которых выделяются дескрипторы для интеллектуальных агентов, предназначенных для гетерогенных классификаторов риска инфекционных заболеваний.

Ключевые слова: искусственный интеллект, инфекционные заболевания, биоимпедансные исследования в аномальных зонах электропроводности, автономные интеллектуальные агенты.

Введение. В качестве количественной оценки риска инфекционного заболевания используется количественная оценка вероятности неблагоприятного исхода при контакте с инфекцией (заболевания) с помощью различных шкал риска. Как правило, эти шкалы проградуированы в баллах, а решение по риску является лингвистической переменной. Несмотря на то, что на балльных шкалах эти заключения не пересекаются, то есть формально не являются нечеткими множествами, они могут быть «размыты» на основе экспертных заключений или статистического анализа. Нечеткие множества термов вводятся посредством функций принадлежности [1].

Учитывая многочисленные исследования в области риска социально-значимых заболеваний, проведенные как на кафедре биомедицинской инженерии ЮЗГУ, так и другими исследователями, при построении интеллектуальной системы по оценке инфекционного риска факторы риска можем разбить на три группы, на основе которых сформируем три автономных интеллектуальных агента (АИА) нижнего иерархического уровня.

Факторы риска, входящие в первую группу назовем основными или общими факторами риска:

- войны; социальные, экономические, стихийные бедствия и т.п.;
- моральные, психические травмы, стрессы;
- тяжелые длительные, изнуряющие организм болезни;
- плохие жилищно-бытовые условия, неблагоприятные условия на рабочем месте;
- нарушение правил личной гигиены;
- контакт с инфицированными людьми их личными вещами;
- нарушение гигиены жилища, служебных помещений;
- не обращение к помощи врача или несвоевременное, некачественное оказание медицинской помощи;
- употребление для питья, а также при умывании некачественной воды;
- употребление пищи, зараженной возбудителями инфекционных болезней;
- отказ от прививок против столбняка при ранениях;
- алкоголизм, наркомания, беспорядочная половая жизнь.

Ко второй группе факторов риска отнесем специфические факторы риска, которые ориентированы на конкретный вид патологии. Имеются специализированные шкалы по хирургии, онкологии, урологии, педиатрии и т.д. [2, 3]. В распоряжении врача должна быть база данных этих шкал, а также база нечетких и четких импликаций, которые позволяют включить эти шкалы в систему нечеткого вывода. Таким образом, каждая специфическая шкала риска может быть представлена функциями принадлежности.

Результаты решений специфических шкал риска, если их несколько, агрегируются посредством нечетких импликаций. При этом нет необходимости нормировать шкалы или приводить их к одинаковой длине [2, 3].

К третьей группе факторов риска отнесем неспецифические факторы, которые определяют устойчивость функциональных систем (ФС) организма при воздействии внешних неблагоприятных факторов. Эта группа, как правило, латентных факторов, характеризует способность организма поддерживать или формировать ФС, обеспечивающие гомеостаз организма. Эти факторы исследуются многими авторами, но, как правило, носят различные названия и определяются по различным методикам.

В работах [4, 5] они интегрированы как механизм защитных свойств организма. Уровень защитных свойств организма UZ определяется через величину адаптационного потенциала (АП), по показателю адаптационного соотношения (ПАС) и по набору лабораторных показателей:

- иммунорегуляторный коэффициент CD4+/CD8+(индекс);
- CD4+25+Т-лимфоциты, экспрессирующие рецепторы к IL2 (процент от CD4+Т-клеток);
- активированные NK- клетки (экспрессирующие HLA-DR-молекулы) (процент от NK-клеток);
- фенопик NK-клеток CD3-16+56-(высокая)(процент).

Аналитические выражения для значения величины UZ можно найти в работах [4, 5].

Другой подход к определению и обобщению этой группы факторов риска изложен в работах [6, 7]. В них введено понятие структурно функциональных единиц (СФЕ), которые являются строительным материалом для создания функциональных систем. Согласно [6] для создания ФС необходимо достаточное количество не активированных (не задействованных в других функциональных системах) СФЕ, а также возможности менеджмента оперировать этими СФЕ. Чтобы определить наличие этих двух условий создаются различные методики тестирования, предусматривающие различные функциональные пробы и методики оценки соответствующих реакций на эти функциональные пробы.

Кроме методик, направленных на исследование стрессоустойчивости пациента, представленных в виде психофизиологических тестов и нагрузочных проб, известно множество методик оценки функционального состояния пациента, основанных на исследовании энергетических характеристик БАТ, связанных с функциональными системами организма. Так как адаптационный потенциал организма определяется сердечно-сосудистой системой (ССС), то выбор БАТ определяется их связью с ССС. Анализ атласов меридиан показал, что с ССС связаны точки E9 и E36 меридиана желудка, GI11 меридиана толстой кишки, RP2 меридиана селезенки – поджелудочной железы, а также вне меридианные точки PC3, PC132 [8].

Методы и модели. Одним из недостатков энергетических показателей БАТ является их высокая чувствительность к изменению неконтролируемых экзогенных и эндогенных факторов и как следствие, высокий динамический диапазон фоновых значений этих показателей. Поэтому основным направлением в усовершенствовании методов контроля функционального состояния на основе энергетических показателей БАТ, является переход от абсолютных значений показателей к относительным значениям.

Получение относительного показателя предусматривает выбор схемы нормирования абсолютных значений измеряемой величины. Схемы основаны на нормировании по статистическим показателям или по выбранным шкалам (например, по максимальному отклонению). Однако, в случае с БАТ использование таких схем нормирования не представляется возможным в связи с зависимостью статистических показаний не только от состояния экзогенной и эндогенной среды, но и от конституционных особенностей самого индивидуума.

Предлагаемая схема нормирования основана на контроле динамики энергетических характеристик БАТ в процессе периодического управляемого воздействия на БАТ экзогенным фактором.

В качестве экзогенного воздействия на БАТ использовались токовые посылки ступенчатой формы, эпюры которых представлены в правой нижней части рисунка 1. Реакцией первичного ответа служит ток в БАТ, который откладывается по оси ординат на графике вольтамперной характеристики (ВАХ), представленной на рисунке 1.

Для определения «реакции платы» следует рассмотреть нисходящую ветвь ВАХ, которая на рисунке 1 показана красным цветом. Реакция платы – это разность ординат восходящей ВАХ (зеленой) и нисходящей ВАХ (красной) при общей для обеих ВАХ абсциссе. От абсолютных значений тока переходим к нормированным значениям путем деления его на соответствующую абсциссу (напряжение), то есть оперируем уже с электрическим сопротивлением БАТ.

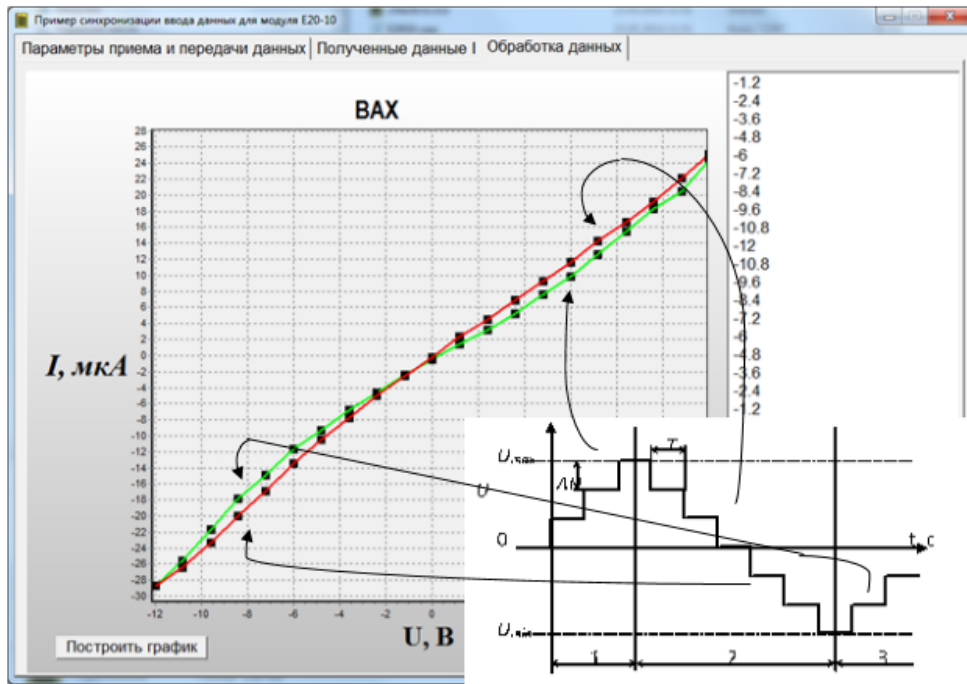


Рисунок 1. Интерфейсное окно для построения графика ВАХ

Формирование дескрипторов, предназначенных для классификации критических состояний человека, осуществлялось посредством анализа континуума реверсивных ВАХ БАТ. Каждая реверсивная ВАХ (рисунок 1) состояла из восходящей и нисходящей ветвей [9, 10, 11, 12, 13, 14]. Пространство дескрипторов строится для каждой информативной абсциссы и состоит из пар двухкомпонентных векторов. Для принятия решения в таком классификационном пространстве используется автономный интеллектуальный агент. Число автономных интеллектуальных агентов соответствует число информативных абсцисс, используемых для формирования пространства информативных признаков.

Каждая пара векторов соответствует информативной абсциссе, примеры которых показаны на рисунке 2. На этом рисунке показаны две информативных абсциссы, соответствующие ординатам $I1$ и $I2$. Число информативных абсцисс и их координаты подбирались эмпирически.

Компонентам векторов соответствуют точки ВАХ, лежащие на этой абсциссе, таким образом, что первому вектору соответствуют точки пересечения абсциссы с восходящими ветвями ВАХ, а второму – нисходящими ветвями ВАХ. Компоненты вектора определяются как

$$\Delta R_i = ((R_{i+1} - R_i) / R_i) * 100, \quad (1)$$

$$\Delta R_j = ((R_{j+1} - R_j) / R_j) * 100, \quad (2)$$

где $i=0...n-1, j=0...n-1, n$ – число ВАХ в континууме, ΔR_i – относительное изменение сопротивления в двух смежных восходящих ВАХ, ΔR_j – относительное изменение сопротивления двух смежных нисходящих ветвей ВАХ.




Рисунок 2. Упрощенная модель континуума ВАХ, иллюстрирующая процесс формирования пространства информативных признаков: a_i – координаты оси абсцисс, соответствующие точкам пересечения ВАХ и информативной абсциссы I_2 восходящих ветвей первого квадранта ВАХ, b_j – координаты оси абсцисс, соответствующие точкам пересечения ВАХ и информативной абсциссы I_2 нисходящих ветвей первого квадранта ВАХ

Учитывая, что формулы (1) и (2) вычисляются при $I=const$, то их можем переписать в следующем виде

$$\Delta R_i = ((a_{i+1} - a_i) / a_i) * 100, \quad (3)$$

$$\Delta R_j = ((b_{j+1} - b_j) / b_j) * 100. \quad (4)$$

Таким образом, для каждой информативной абсциссы в первом квадранте может быть сформирован следующий вектор дескрипторов

$$\{(\Delta R_1^1, \Delta R_1^2), (\Delta R_2^1, \Delta R_2^2), \dots, (\Delta R_k^1, \Delta R_k^2), \dots, (\Delta R_{n-1}^1, \Delta R_{n-1}^2)\}, \quad (5)$$

где верхними индексами 1 и 2 обозначены относительные изменения сопротивлений, соответственно, в восходящих и нисходящих ветвях ВАХ.

Если есть необходимость учитывать дескрипторы, получаемые по результатам анализа ВАХ и в третьем квадранте, то необходимо построить информативную абсциссу для отрицательных токов, которые откладываются в третьем квадранте, и получить вектор информативных признаков, аналогичный выражению (5).

Дескрипторы формировались по каждому пациенту из оцифрованных ВАХ БАТ путем выбора информативных абсцисс $I_1=20$ мкА и $I_2=-20$ мкА. (рисунок 3). Значение ΔR_i и ΔR_j находили по формулам (3), (4).




Рисунок 3. Расположения исследуемых точек на ВАХ

Заключение. Математические эксперименты по разработке методики прогнозирования инфекционных заболеваний осуществлялись в пакете Матлаб с использованием инструментариев построения искусственных нейронных сетей и систем нечеткого вывода.

Благодарность. Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-38-90063.

Acknowledgments: The reported study was funded by RFBR, project number 20-38-90063.

Библиографический список

1. Корневский Н.А., Филист С.А., Красковский А.Б. и др. Теория проектирования нечетких сетевых экспертных систем для управления медико-экологической безопасностью // Научные ведомости Белгородского государственного университета. Серия: История. Политология. Экономика. Информатика. 2009. № 9-1 (64). Том 11. С.146-151.
2. Александрович, Ю.С. Оценочные и прогностические шкалы в медицине критических состояний / Ю.С. Александрович, В.И. Гордеев. – СПб.: Сотис, 2007.- 140 с.
3. Левин, О.С. Клинические шкалы в неврологии / О.С. Левин, Е.Е. Васенина, О.А. Ганькина, А.Ш. Чимагомедова. – М.: МЕДпресс-информ, 2019. – 192 с.
4. Корневский, Н. А. Комплексная оценка функциональных резервов человека с использованием методов рефлексодиагностики. / Н.А. Корневский, В.В. Буняев, СВ. Корепов // Системный анализ и управление в биомедицинских системах. – 2003. – Т. 2. – №2. – С. 182-185.
5. Корневский, Н.А, Оценка и управление состоянием здоровья обучающихся на основе гибридных интеллектуальных технологий:

- монография / Н.А. Корневский, А.Н. Шуткин, С.А. Горбатенко, В.И. Серебровский. – Старый Оскол: ТНТ, 2016. – 472 с.
6. Шуткин, А.Н. Структурно-функциональная модель для мониторинга влияния управляющих воздействий на функциональное состояние самоорганизующихся систем / А.Н. Шуткин, П.С. Кудрявцев, В.В. Протасова [и др.] // Прикаспийский журнал: управление и высокие технологии. Научно-технический журнал. – 2015. – № 2 (30). – С.105-119.
 7. Гайдес М.А. Общая теория систем (системы и системный анализ) / М.А. Гайдес // – Тель Авив: Госпиталь им. Хаима Шибы, Тель Ашомер, 2004.-360 с.
 8. Лувсан Г. Очерки методы восточной рефлексотерапии / Г. Лувсан. – 3-е изд., перераб. и доп. – Новосибирск: Наука. Сиб. отд-е, 1991. – 402 с.
 9. Дегтярев, С.В. Моделирование биоимпедансных исследований средствами MATLAB / С.В. Дегтярев, О.В. Шаталова, А.Ф. Рыбочкин, А.А. Кузьмин // Медицинская техника. – 2013. – № 4 (280). – С. 27-29.
 10. Мохаммед, А.А. Моделирование импеданса биоматериалов в среде MATLAB / А.А. Мохаммед, С.А. Филист, О.В. Шаталова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2013. – № 4. – С. 73-78.
 11. Шаталова, О.В. Применение автоматизированной системы для исследования вольтамперных характеристик биоматериалов / О.В. Шаталова, С.Е. Суржикова, А.С. Богданов // Биомедицинская радиоэлектроника. – 2014. – № 9. – С. 43-46.
 12. Филист, С.А. Модели биоимпеданса при нелинейной вольтамперной характеристике и обратимом пробое диэлектрической составляющей биоматериала / С.А. Филист, О.В. Шаталова, А.С. Богданов // Бюллетень сибирской медицины. – 2014. – Т. 13, № 4. – С. 129-135.
 13. Суржикова, С.Е. Программно-аппаратный комплекс для анализа вольтамперных характеристик биоактивных точек на основе модуля L-CARD E20-10 / С.Е. Суржикова, О.В. Шаталова, В.В. Федянин // Прикаспийский журнал: управление и высокие технологии. – 2015. – № 2 (30). – С. 150-161.
 14. Суржикова, С.Е. Исследование проводимости биоматериалов в биоактивных точках при циклических воздействиях токами различной полярности / С.Е. Суржикова, Ю.Б. Мухатаев, Л.В. Плесканос, О.В. Шаталова // Биомедицинская радиоэлектроника. – 2016. – № 9. – С. 32-37.

METHODS AND MODELS FOR THE FORMATION OF DESCRIPTORS FOR INTELLIGENT SYSTEMS FOR ASSESSING THE RISK OF INFECTIOUS DISEASES BASED ON ANALYSIS OF THE BIOIMPEDANCE OF ZONES OF ANOMALOUS ELECTRIC CONDUCTIVITY

Miroshnikov Andrey V., Protasova Zeinab U., Shatalova Olga V.

Southwest State University

305040, Russia, Kursk, st. 50 years of October, 94, Shatolg@mail.ru

The article presents a study of the dynamic characteristics of bioimpedance in areas of abnormal electrical conductivity, on the basis of which descriptors are identified for intelligent agents intended for heterogeneous classifiers of the risk of infectious diseases.

Key words: artificial intelligence, infectious diseases, bioimpedance studies in abnormal zones of electrical conductivity, autonomous intelligent agents.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА КЛАССИФИКАЦИИ МУЗЫКАЛЬНЫХ ИНСТРУМЕНТОВ

Варельджан Гарник Варткесович, Еленский Михаил Витальевич

Пермский государственный национальный исследовательский университет,

ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15

gavid19912@gmail.com, elenskii-mikhail@outlook.com

В статье представлено описание разработки нейросетевой системы для классификации музыкальных инструментов. Система позволяет классифицировать некоторый список музыкальных инструментов, используемых в аудиофайле. Был проведен ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: классификация, нейронные сети, сверточные нейронные сети, музыка, мел-кепстральные коэффициенты.

Введение. Задача классификации звуков музыкальных инструментов несмотря на значительный прогресс в схожих областях, например распознавание речи или распознавание нот, остается в достаточной степени актуальной.

В качестве входных данных использовались мел-кепстральные коэффициенты (mel-frequency cepstral coefficients, MFCC) – набор коэффициентов, характеризующих сигнал на основе его спектра и амплитуды. Данные коэффициенты являются одной из лучших из существующих на данный момент аппроксимаций человеческого слуха. Данные коэффициенты

успешно применяются для решения задач как распознавания речи, так и музыкальной классификации, в том числе и музыкальных инструментов. Алгоритм вычисления мел-коэффициентов можно представить следующим образом:

1. Разбиение исходного на короткие промежутки – окна, длиной 20-40 мс, на которых значение сигнала считается постоянным.
2. Вычисления спектра сигнала для каждого окна на основании преобразования Фурье.
3. Расчет спектральной площади и применение мел-шкалы.
4. Выполнение дискретного косинусного преобразования.

В работе [1] есть подробное описание каждого из шагов данного алгоритма.

Для обучения модели использовался датасет «Freesound General-Purpose Audio Tagging Challenge», а именно его часть, содержащая следующий список инструментов:

1. Акустическая гитара;
2. Большой барабан;
3. Кларнет;
4. Контрабас;
5. Пианино;
6. Флейта;
7. Хай-хет;
8. Саксофон;
9. Малый барабан;
10. Тромбон;
11. Труба;
12. Скрипка.

Всего 3995 треков различной длины. Все треки были обрезаны с начала и конца таким образом, чтобы избавиться от тишины. После этого они были разбиты на секундные отрезки, файлы, имеющие меньшую длину, были дополнены нулями. Таким образом было получено 20650 секундных файлов, в которых практически отсутствует пустота. Далее работа велась в двух направлениях: мультиклассовой классификации и одноклассовой классификации.

В качестве модели было решено использовать EfficientNetB5.

В качестве модели в Нейросимуляторе использовалась полносвязная нейронная сеть с одним скрытым слоем, входной слой состоит из 704-х нейронов, скрытый слой содержит 100 нейронов, выходной 12 нейронов.

Одноклассовая классификация. Модель EfficientNetB5, концепция и архитектура которой изложены в статье [2], показала отличные результаты в контексте экспериментов с одноклассовой классификацией.

В качестве функции потерь использовалась мультиклассовая кросс-энтропия.




Рисунок 1. Значения функции потерь в ходе обучения

Также использовался callback ReduceLROnPlateau с параметрами: patience = 7, factor = 0.35, min_lr = 1e-6.




Рисунок 2. График точности сети в ходе обучения

Итоговая тестовая точность составила 93%, что в теории является достаточным в контексте будущего приложения.

Данная модель используется в прототипе приложения.

Работа с Нейросимулятором была сопряжена с рядом технических проблем, вызванных несовершенством данной системы. Основной проблемой является производительность данной системы. При работе с полным набором данных программа отказывалась загружать данные в обучающее множество, поэтому было решено использовать небольшой набор из 400 треков в обучающем множестве и 200 треков в тестовом.



Рисунок 3. Среднеквадратичная ошибка обучения-тестирования

Как мы видим, Нейросимулятор дает даже несколько лучшие результаты, однако ограниченность по объему данных, невозможность прямой интеграции в приложение играют в нашем случае решающую роль, поэтому дальнейшие работы велись без его использования.

Мультиклассовая классификация. Несмотря на множество экспериментов, каких-либо удачных результатов добиться не удалось. Как выяснилось стандартный подход в данной задаче не способен дать хорошего результата. Главными проблемами являются: суперпозиция инструментов, различия в тембре одного инструмента, различия в тембре одного инструмента, а также множество других проблем связанных с наложением звуков.

Классический подход в обучении моделей в контексте данной задачи не способен дать каких-либо удовлетворительных результатов, однако некоторые другие решения, например Multiple instance learning рассмотренный в статье [3], позволяет решить данную проблему.

- Разработка программного обеспечения. Для решение данной задачи отлично подходит технология нейронных сетей. В данной работе используются два инструмента для реализации нашего решения, это библиотека Keras с бэкендом Tensorflow. Так же был написан, прототип конечного приложения на фреймворке PySide2. Для предварительной обработки аудиофайлов использовалась библиотека Librosa.

- В общих словах, приложение работает следующим образом: на вход подается обученная модель и аудиофайл или несколько аудиофайлов, после чего файлы нарезаются на секундные отрезки, далее на модель определяет на каждом отрезке основной инструмент. Пользователю выдается список инструментов и количество секунд каждого инструмента в песне.

- Прототип приложения имеет следующую архитектуру:

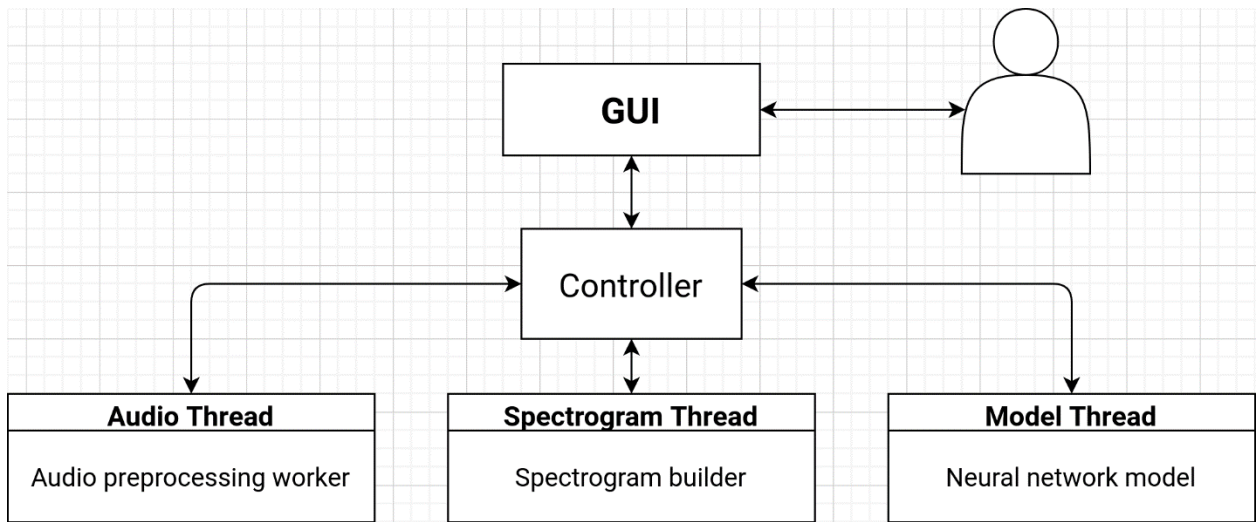


Рисунок 3. Архитектура приложения

▪ Приложение представляет собой четыре явных потока. Первый основной поток обрабатывается графический интерфейс и происходит диалог с пользователем. Второй поток загружает модель в память и производит анализ входного файла. Третий поток загружает аудиофайл. Четвертый поток строит спектрограмму входного файла.

В качестве ответа пользователь получает список инструментов вида [Инструмент – Количество секунд в треке, которые были сопоставлены с ним].

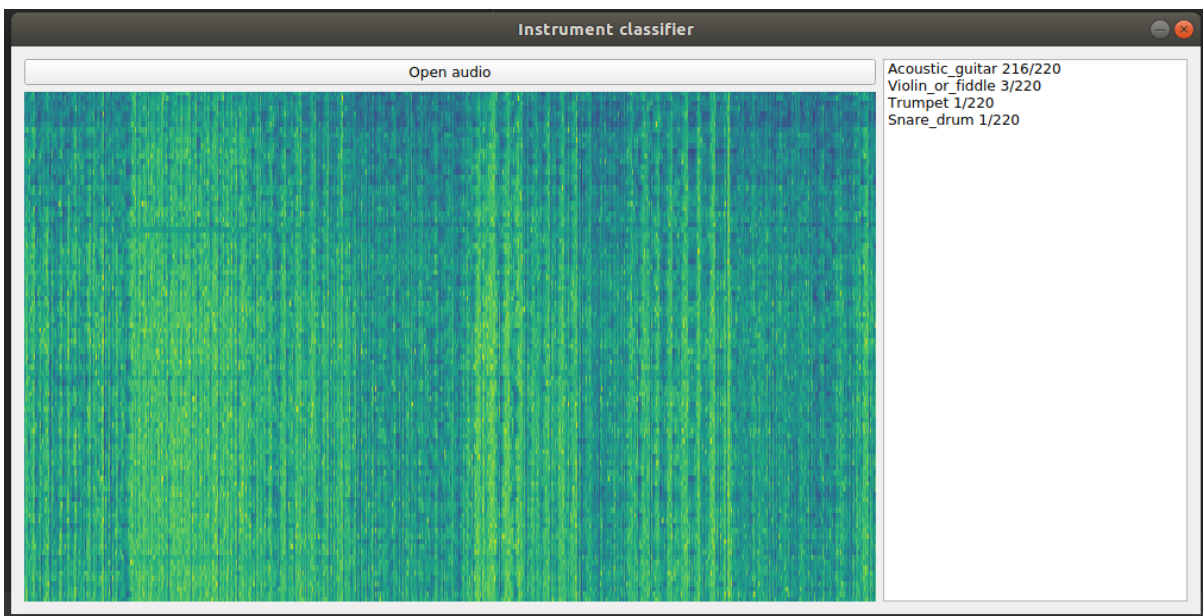


Рисунок 4. Графический интерфейс приложения

Ниже приведены результаты тестирования прототипа продукта на некоторых музыкальных композициях:

Таблица 1 – Результаты тестов на реальных композициях.

Виктор Цой – Пачка Сигарет	Малый барабан 84 / 268 Акустическая гитара 72 / 268 Труба 65 / 268 Саксафон 26 / 268 Бочка 7 / 268 Хай-хэт 4 / 268
Вивальди – Времена года. Зима	Скрипка 108 / 203 Труба 44 / 203 Саксофон 24 / 203 Контрабас 18 / 203 Флейта 13 / 203
Creedence Clearwater Revival – Have You Ever Seen The Rain	Акустическая гитара 109 / 158 Саксофон 23/158 Малый барабан 16 / 158
New York Jazz – Sunny	Акустическая гитара 175/318 Малый барабан 47/318 Бочка 25/318 Электропианино 23/318 Скрипка 21/318 Контрабас 13/318 Хай-хэт 7/318
WWE Kurt Angle	Труба 51/168 Саксофон 45/168 Скрипка 21/168 Малый барабан 17/168 Акустическая гитара 14/168 Хай-хэт 9/168
Военный оркестр – Священная Война	Скрипка 67/115 Саксофон 24/115 Труба 8/115 Акустическая гитара 8/115
Jeremy Soule – Nerevar Rising (Morrowind Title Song)	Саксофон 56/114 Скрипка 31/114 Труба 10/114 Бочка 10/114

Как мы видим, подобный подход плохо применим к реальным произведениям с множеством инструментов, особенно в случае оркестровой музыки. Однако на однородных произведениях точность предсказания достаточно высокая. Что еще раз подтверждает невозможность решения данной задачи классическими методами.

Заключение. Построенная нейросетевая система и сопутствующее программное обеспечение позволяет с очень высокой точностью определять

инструменты в случае, если одновременно звучит лишь один инструмент, в случае полифонии точно заметно снижается причем определяется лишь ведущий инструмент. Кроме того, многие композиции содержат в себе партии инструментов отсутствующих в обучающем множестве. Точность предсказания для таких треков заметно снижается.

Однако в случае, если все перечисленные условия соблюдены модель в тандеме с приложением может оказаться достаточно интересным инструментом с точки зрения конечного пользователя.

Исходный код программы открыт и доступен в репозитории [4].

Библиографический список

1. Станкевич Ф.В. Распознавание музыкальных инструментов на основе нейросетевого анализа амплитудно-частотных характеристик / Станкевич Ф.В.; Томск. Национальный исследовательский политехнический университет.
2. Mingxing Tan and Quoc V Le. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // <https://arxiv.org/pdf/1905.11946.pdf>
3. Siddharth Gururan, Mohit Sharma, Alexander Lerch. An attention mechanism for musical instrument recognition. // <http://archives.ismir.net/ismir2019/paper/000007.pdf>
4. Репозиторий <https://github.com/mkls6/instrument-classification>
5. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007.

MUSICAL INSTRUMENT CLASSIFICATION USING NEURAL NETWORKS

Vareldzhan Garnik V, Elenskii Mikhail V.
Perm State University
Str. Bukireva, 15, Perm, Russia, 614990,
gavid19912@gmail.com, elenskii-mikhail@outlook.com

The article describes the development of musical instrument classifier using neural networks. The classifier system allows to identify a set of musical instruments used in audio files. During the development a number of studies were made. The results are given in the article.

Keywords: classification, neural networks, convolutional neural networks, music, MFCC.

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ РИСКА ВНЕБОЛЬНИЧНОЙ ПНЕВМОНИИ

Мяснянкин Максим Борисович, Филист Сергей Алексеевич
Юго-Западный государственный университет,
305040, Россия, г. Курск, ул. 50 лет Октября, 94, SFilist@gmail.com

В статье представлено описание разработки классификатора риска внебольничной пневмонии на основе предикторов, формируемых посредством анализа синхронности системных ритмов сердечно-сосудистой системы и дыхательной системы и нейросетевого моделирования. В качестве источников системных ритмов используются электрокардиосигналы и электромиосигналы. Предложен алгоритм классификации риска внебольничной пневмонии по показателям синхронности системных ритмов. **Ключевые слова:** внебольничная пневмония, факторы медицинского риска системных ритмов, нейросетевые технологии, спектральные характеристики сигналов.

Введение. Внебольничная пневмония (ВП) занимает лидирующее положение среди болезней органов дыхания в связи с высоким уровнем заболеваемости и смертности во всех возрастных группах [1]. В настоящее время разработано и предложено несколько шкал, которые на основании риска неблагоприятного исхода болезни позволяют выбрать место лечения больного ВП (амбулаторные условия, госпитализация в общетерапевтическое отделение). Исследование литературных источников показало, что для формирования этих шкал медицинского риска используется концепция факторов риска (ФР). В настоящее время существует несколько вариантов оценки прогноза при ВП. Наиболее изученными из них являются шкалы риска ВП PSI и CURB-65. Эти шкалы предназначены для выявления больных с неблагоприятным прогнозом, при этом они не являются непосредственным инструментом для оценки степени тяжести ВП, а также не могут полностью заменить клиническое решение при выборе места лечения больного. Шкалы помогают унифицировать подход к описанию популяции больных ВП, выделять различные группы риска, что важно при проведении клинических исследований.

Существует несколько моделей для расчета популяционного риска. Все они базируются на многофакторном анализе риска заболевания в больших популяциях, за которыми проводится длительное наблюдение. Эти системы, безусловно, нельзя считать совершенными. Прежде всего, в них учитываются далеко не все известные в настоящее время ФР. Еще одной проблемой является то, что в большинстве этих систем не учитываются региональные

особенности, характер питания и некоторые другие факторы, которые, несомненно, влияют на прогноз.

Необходимость системного подхода к оценке функционирования человеческого организма в конкретных условиях жизнедеятельности была осознана еще древними врачами Востока [2]. В последние годы разработана технология оценки совокупного риска основных социально значимых заболеваний («ОРИСКОН»), которая является оригинальной экспертной системой. В ней впервые оценивается риск развития основных хронических заболеваний, имеющих общие ФР и единые концептуальные основы профилактики [3]. Основные социально значимые заболевания включают основные ССЗ (ИБС, цереброваскулярную болезнь и другие ССЗ, связанные с атеросклерозом), онкологические заболевания, заболевания легких, эндокринные, заболевания органов пищеварения, а также ряд нестрого установленных причин.

Шкалы оценки величины риска позволяют оценить не только индивидуальный риск, но и провести моделирование развития эпидемиологической ситуации в зависимости от выбранного варианта профилактического вмешательства. Вместе с тем очевидна необходимость развития данного направления, продолжения исследований по изучению механизмов реализации медицинского риска и внедрения новых технологий, разрабатываемых на основе новых знаний, в профилактическую медицину.

Рассмотренные современные системы стратификации медицинского риска нельзя считать совершенными, так как в них учитываются далеко не все известные в настоящее время факторы риска, а сделан акцент на традиционных факторах и методах моделирования. Таким образом, в современных условиях традиционных факторов риска и методических подходов к построению интеллектуальных систем прогнозирования рисков недостаточно для надежного предсказания возникновения заболеваний. Поэтому перспективным является включение ряда новых факторов в прогностическую модель, в частности модель ВП, которые могут быть использованы в системах стратификации риска у лиц, не имеющих клинических проявлений внебольничной пневмонии, а также разработки новой методологии построения моделей медицинского риска.

Методы и модели. Большинство процессов, анализ которых дает основной объем диагностической информации, имеют колебательный характер. В технике это механические, электромагнитные и другие виды колебаний. В биологии, медицине и экономике – ритмы, циклы и т.д. В системах с гомеостазом выделяют собственные (резонансные) колебания и колебания подсистемы регулирования, работа которой основана на принципе обратной связи. В живых системах выделяют множество подсистем регулирования, которые являются источником вынужденных колебаний для колебательных систем нижнего уровня. Вынужденные колебания проявляются в основном в виде модуляции (амплитудной и/или частотной) собственных колебаний. В результате сигналы приобретают сложную форму, характеризующую совокупностью различных колебательных составляющих,

отличающихся по амплитуде, фазе, частоте. Математическим аппаратом, с помощью которого эти составляющие могут быть выделены, является преобразование Фурье.

В качестве источника релевантных ритмов выделяют кардиоритмы и ритмы дыхательной системы. Несмотря на некоторую их корреляцию, эти ритмы имеют существенное отличие, определяющееся тем, что дыхательным ритмом, в отличие от кардиоритма, человек может осознанно управлять, что часто используется в реабилитационных системах, известных как системы кардиореспираторного резонанса, которые являются эффективным нефармакологическим способом коррекции вегетативного баланса.

Кардиореспираторная система, состоящая из сердечно-сосудистой системы и системы дыхания, является наиболее чутким индикатором физиологического состояния организма. Структуры мозга, отвечающие за ритмогенез дыхания и сердца, связаны друг с другом. Координация ритмогенеза дыхания и ритма сердца столь значима, что эти структуры образуют функциональное единство. На ранних стадиях заболевания или в состоянии предболезни (в преморбидном состоянии) это единство нарушается, что в первую очередь отражается на изменении спектральных характеристик системных ритмов и их корреляционных показателей. Анализ кардиоритма используется для контроля адаптационным потенциалом человека, который может быть отнесен к суррогатному маркеру иммунитета человека. На вариабельность сердечного ритма и дыхания оказывает влияние бронхиальная обструкция. Анализ ритма дыхания менее освещен в научной литературе. Тем не менее, известно ряд экспериментальных работ, в которых показано, что электромиограмма дыхательных мышц является индикатором состояния дыхательной системы. В этих работах показано, что электрическая активность дыхательных мышц является информативным параметром при диагностике нарушений функционального состояния дыхательной системы [4, 5, 6].

В качестве основы для построения модели прогнозирования внебольничной пневмонии взяты технические решения, предложенные в работах [7, 8]. Сущность предлагаемого технического решения состоит в следующем. Если имеются возможность разделить имеющиеся данные на сегменты по естественному или искусственному принципу, то для каждого сегмента имеется возможность построить автономный интеллектуальный агент, который займет соответствующее место в системе интеллектуальных агентов. Верхний уровень иерархии занимает нейронная сеть, которая в процессе обучения определит информативную ценность каждого автономного интеллектуального агента или группы автономных агентов, объединяемых в соответствующую иерархическую структуру. При наличии надежной экспертной информации, ее можно ввести в иерархический классификатор. Например, добавить параллельно к имеющимся автономным интеллектуальным агентам блок нечеткого логического вывода на соответствующем иерархическом уровне [9].

В данном случае имеем два источника данных, которые разделены естественным образом и один из которых связан с сердечно-сосудистой системой, а другой – с системой дыхания. Кроме того, учитывая априорную информацию о влиянии этих систем друг на друга, и учитывая корреляционной связи сигналов, характеризующих жизнедеятельность этих систем, можем выделить еще один кластер дескрипторов и соответствующий автономный агент.

Дескрипторы для автономных интеллектуальных агентов получаем посредством анализа синхронности ритмов в каждой из систем. Один из методов формирования дескрипторов для автономного интеллектуального агента на основе анализа системных ритмов изложен в работе [10]. В общепринятой модели формирования наджелной электромиограммы предполагается [11], что вид регистрируемого сигнала – двойная суперпозиция некоторого количества случайно следующих отдельных миоимпульсов от различных двигательных единиц. Экспериментально установлено [12], что, несмотря на кажущуюся хаотичность вида регистрируемого сигнала, его спектральная мощность имеет вид большого количества узких спектральных линий, ограниченных некоторой плавной огибающей в полосе частот около 100–200 Гц. Показано [13], что спектральная мощность сигнала является произведением трех спектральных функций, первая (условно) из них есть спектр отдельного миоимпульса, который и определяет поведение плавной огибающей узких спектральных линий. Спектр электромиосигнала выглядит сложным и почти хаотическим, однако квадрат Фурье-образа этого спектра уже чрезвычайно прост и представляет собой шесть отдельных спектральных линий. Положения этих спектральных линий определяются временными параметрами электромиосигнала, что может позволить интерпретировать эти спектры автономным интеллектуальным агентом [13].

При вычислении показателей синхронности использовалась корреляционная функция или взаимные спектры наблюдаемого модулированного низкочастотными колебаниями сигнала. Степень корреляции системных ритмов определяет функциональное состояние системы в целом или ее реакцию на экзогенный фактор. Алгоритм классификации риска внебольничной пневмонии по показателям синхронности системных ритмов представлен следующей последовательностью процедур:

- 1) выбрать релевантные системные ритмы;
- 2) исходя из самой низкой частоты релевантного системного ритма, выбрать апертуру наблюдения кардиосигнала таким образом, чтобы в нее входило не менее 10 периодов этой частоты;
- 3) получить кардиосигнал заданной длительности, если необходим прогноз ССР, или получить обучающую выборку, если необходимо построить классификатор ССР;
- 4) построить вейвлет-плоскость (вейвлет-плоскости) кардиосигнала (обучающей выборки);

5) выбрать на вейвлет-плоскости (вейвлет-плоскостях) строки, характеризующие релевантные системные ритмы;

6) трансформировать выбранные строки в матрицу (в матрицы в случае обучающей выборки);

7) определить корреляционные функции для строк построенной матрицы (построенных матриц) при нулевом сдвиге;

8) нормировать полученные корреляционные функции;

9) сформировать вектор информативных признаков из данных, полученных в п.8. Если сигнал стационарен, то перейти к п. 15.

При нестационарном сигнале:

10) определить корреляционные функции для строк построенной матрицы (построенных матриц);

11) нормировать полученные корреляционные функции;

12) определить амплитудные спектры Фурье строк нормированной матрицы (нормированных матриц);

13) определить коэффициенты вариации релевантных ритмов полученных спектров Фурье;

14) сформировать вектора информативных признаков из данных, полученных в п.п. 8, 13;

15) подать сформированные векторы на вход обученной нейронной сети или приступить к обучению нейронной сети.

Для исследования синхронизации 0,1 Гц-ритмов в ЭКГ и электромиограммы дыхательных мышц предполагается использовать метод изучения функционального состояния на основе анализа синхронности 0,1 Гц-ритмов. Из ЭКГ и электромиосигнала (ЭМС) выделяется ритм 0,1 Гц посредством вейвлет-анализа или спектрального анализа. Для оценки синхронности ритмов необходимо определить разность фаз на этой частоте между выделенными гармониками 0,1 Гц ЭМС и ЭКГ в скользящем окне. Для анализа предположительно можно использовались трехминутные записи кардиоосигналов, состоящие из 48000 отсчетов.

По показателю разности фаз подсчитывали общую длительность всех участков синхронизации, т.е. время, на протяжении которого 0,1 Гц-ритмы были синхронизованы во время записи ЭКГ и ЭМС, также выражали его в процентах от длительности всей записи, т.е. рассчитывали суммарный процент синхронизации S . С помощью такого показателя синхронизации S характеризуется относительное время синхронизации между ритмами с частотой около 0,1 Гц в ЭМС и ЭКГ.

«Пороговое» значения показателя S , выше которого можно считать качество функционального взаимодействия 0,1 Гц-механизмов регуляции сердца и ЭМС удовлетворительным, обоснуется при помощи ROC-анализа экспериментальных и контрольных выборок пациентов с внебольничной пневмонией.

Алгоритм определения параметра синхронности использует скользящее окно, в котором определяются спектры Фурье ЭКГ и ЭМС и разность фаз гармоник интереса в скользящем окне ЭКГ и ЭМС. Если эта

разность отличается от усредненной разности фаз по всей апертуре наблюдения на некоторую пороговую величину, то интервалы сигналов, попавшие в скользящее окно, считаются рассинхронизированными.

Показатели синхронности ориентированы на оценку синхронности двух системных ритмов, которые возбуждаются одним и тем же центром, но характеризуют состояние различных подсистем живой системы, например, сердечно-сосудистой и дыхательной.

Заключение. Таким образом, для классификации внебольничной пневмонии, на первом этапе необходимо выбрать носитель (носители) системных ритмов, затем посредством итерационных процедур выбрать сами системные ритмы, наиболее коррелируемые с адаптационным статусом систем организма и организма в целом, построить признаковое пространство (определить дескрипторы), основанное на частотном разложении системных ритмов. После этого разрабатывается классификатор риска внебольничной пневмонии. В этих целях используются гибридные нейросетевые структуры, которые позволяют использовать для построения классифицирующих систем как интуицию и опыт самого исследователя, так и обучающие выборки.

На последнем этапе синтезируется решающий модуль, позволяющий по адаптационным статусам отдельных систем организма выявить риск внебольничной пневмонии.

Благодарность. Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-38-90058.

Acknowledgments: The reported study was funded by RFBR, project number 20-38-90058.

Библиографический список

1. Павлов С. Е., Кузнецова Т. Н. Адаптация и стресс в спорте // В сб.: «Актуальные вопросы медицинской реабилитации в современных условиях» – М., 1999 – С. 307-312.
2. Министерство здравоохранения и социального развития Российской Федерации. Заболеваемость населения России в 2007 г.: Статистические материалы. М., 2008.
3. Шальнова, С. А. Российская экспертная система Оценки РИСКА Основных Неинфекционных заболеваний (ОРИСКОН) / С.А. Шальнова, А.М. Калинина, А. Д. Деев, А.В. Пустеленин. – М.: Кардиоваскулярная терапия и профилактика, 2013, -Т. 4, №12. – С. 55.
4. Ершов С.П., Перельман Ю.М. Электрофизиологическая характеристика дыхательных мышц больных хроническим бронхитом/Бюллетень физиологии и патологии дыхания.
5. Тетенев Ф.Ф. и др. Пиковая скорость выдоха и бронхиальное сопротивление у больных с внебольничной пневмонией/Сибирский медицинский журнал (Иркутск). Т. 58. №8.-2005. С.43-45.
6. Чучалин А.Г., Айсанов З.Р. Нарушение функции дыхательных мышц при хронических обструктивных заболеваниях легких//Терапевтический архив.- 1988.-Т. 60, № 7.- С.126-131.

7. Филист, С.А. Гибридная нейронная сеть с макрослоями для медицинских приложений / С.А. Филист, О.В. Шаталова, М.А. Ефремов // Нейрокомпьютеры. Разработка и применение. – 2014. – №6. – С. 35-39.
8. Филист, С.А. Универсальные сетевые модели для задач классификации биомедицинских данных / С.А. Филист, Р.А. Томакова, З.Д. Яа // Известия Юго-Западного государственного университета. – Курск: Изд-во ЮЗГУ, 2012. – №4(43). – Ч. 2. – С. 44-50.
9. Корневский Н.А., Филист С.А., Красковский А.Б. и др. Теория проектирования нечетких сетевых экспертных систем для управления медико-экологической безопасностью // Научные ведомости Белгородского государственного университета. Серия: История. Политология. Экономика. Информатика. 2009. № 9-1 (64). Том 11. С.146-151.
10. Петрова, Т.В. Предикторы синхронности системных ритмов живых систем для классификаторов их функциональных состояний / Т.В. Петрова, С.А. Филист, С.В. Дегтярев, А.В. Киселев, О.В. Шаталова // Системный анализ и управление в биомедицинских системах. 2018. Т. 17. № 3. С. 693-700.
11. Физиология человека / под ред. Г.И. Косицкого. – М., 1985.
12. Рангайян Р.М. Анализ биомедицинских сигналов. Практический подход / под ред. А.П. Немирко. – М., 2007.
13. Шайдук А.М., Останин С.А. Расшифровка спектра электромиограммы методом двойного Фурье-преобразования // Известия Алтайского государственного университета. 2011. №1-2 (69). – С.186-191.

NEURAL NETWORK SYSTEM FOR EVALUATING THE RISK OF OUTSTANDING PNEUMONIA

Myasnyankin Maxim B., Philist Sergey A.

Southwest State University

305040, Russia, Kursk, st. 50 years of October, 94, Sfilist@gmail.com

The article describes the development of a risk classifier for community-acquired pneumonia based on predictors generated by analyzing the synchronicity of systemic rhythms of the cardiovascular system and the respiratory system and neural network modeling. Electrocardiosignals and electromyosignals are used as sources of systemic rhythms. An algorithm for the classification of the risk of community-acquired pneumonia by indicators of the synchrony of systemic rhythms is proposed.

Key words: community-acquired pneumonia, medical risk factors, systemic rhythms, neural network technologies, spectral characteristics of signals.

ДИНАМИЧЕСКАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ ВТОРИЧНОГО РЫНКА ЖИЛОЙ НЕДВИЖИМОСТИ НИЖНЕГО НОВГОРОДА

Минин Андрей Сергеевич, Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет,
ПМИ., 614990, Россия, г. Пермь, ул. Букирева, 15, yasn@psu.ru

В статье представлено описание разработки динамической нейросетевой системы для прогнозирования стоимости жилой недвижимости вторичного рынка для г. Нижний Новгород. Система позволяет выполнять оценку стоимости квартир с учетом географических, строительных и макроэкономических показателей. Использование макроэкономических параметров позволяет сделать систему адаптируемой к текущей экономической ситуации.

Ключевые слова: искусственный интеллект, нейросетевые технологии, вторичный рынок квартир, самоадаптация, оценка стоимости, прогнозирование, жилая недвижимость.

Введение. При продаже или отчуждении объекта недвижимости требуется выполнить корректную оценки его стоимости. Обычно такие услуги оказывают агентства недвижимости, риэлторы, но как правило, такой подход подвержен влиянию человеческого фактора, например, можно не учесть какой-либо критерий и сформировать некорректную итоговую стоимость объекта.

Эффективность использования искусственного интеллекта при оценке стоимости недвижимости была обоснована в работах зарубежных исследователей [1-3]. В данных работах наборы параметров, используемые для оценки объектов, не учитывают экономическую обстановку, которая также может оказывать влияние на формирование цен объектов недвижимости.

Авторы работ [4-7] предложили способ создания динамических систем для прогнозирования стоимости недвижимости с учетом географических, строительных и изменяющихся экономических параметров, таких как цена на нефть, курс доллара, объем ипотечных кредитов, ввод жилья в регионе, ВВП и др. Модели [4-7] способны адаптироваться к текущей экономической обстановке и не теряют актуальности со временем.

Данное исследование является продолжением вышеупомянутых работ по созданию динамической системы оценки недвижимости. Основная цель настоящей работы заключается в сборе множества о квартирах,

продающихся на вторичном рынке в г. Нижний Новгород, а также создание и обучение нейросетевой модели на этих данных.

В результате анализа литературных источников [1-7], был выбран следующий набор показателей: X1 – индекс города, X2 – широта, X3 – долгота, X4 – тип стен, X5 – количество комнат, X6 – этаж, X7 – этажность, X8 – общая площадь (кв. м.), X9 – жилая площадь (кв. м.), X10 – площадь кухни (кв. м.), X11 – сезон, X12 – год, X13 – курс доллара (руб. за 1 доллар), X14 – цена на нефть (руб.), X15 – ВВП в текущих ценах за прошлый год (млрд. руб.), X16 – ввод жилья за прошлый год (тыс. кв. м.), X17 – ипотечные кредиты за прошлый год (млн. руб.). Выходной параметр D1 – стоимость квартиры (руб.).

Параметр тип стен был закодирован: 1 – блочный, 2 – шлакоблок, 3 – дерево, 4 – монолит, 5 – газобетон, 6 – панель, 7 – кирпич. Остальные параметры являются числовыми, поэтому для них кодировка не требуется. Также такой формат данных обуславливается тем, что собранное множество будет добавлено в общее множество проекта по созданию самоадаптируемой интеллектуальной системы оценки рынка недвижимости городов Российской Федерации. В связи с этим, для разделения квартир по городам был введен параметр индекса города, где Нижнему Новгороду соответствует значение 8.

В отличие от работ [4-7], для учета местоположения квартир, вместо расстояний до локальных ценовых центров, районов предлагается использовать географические координаты – широта, долгота.

Множество объявлений о квартирах, продающихся на вторичном рынке в г. Нижний Новгород, было собрано с помощью программы-парсера с интернет-ресурсов. Перед переходом к проектированию и обучению нейросетевой модели, была выполнена очистка исходного множества от противоречивых примеров, выбросов, дубликатов. Например, некорректными примерами считались те, где сумма жилой площади и кухни превышает общую площадь, а также объявления, в которых цена занижена или завышена в десятки раз. Таким образом, объем итогового множества включает в себя 6292 примеров. Данное множество было разделено на обучающее и тестирующее в соотношении 80% и 20% соответственно. Собранные данные охватывают период февраль-март 2020 года.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [8] по методике [9]. В результате оптимизации спроектированная нейронная сеть представляла собой перцептрон, который имеет семнадцать входных нейронов, один выходной и один скрытый слой с шестью нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 1230 примеров. Средняя ошибка тестирования составила 11.8%, что можно считать приемлемым результатом. На рисунке 1 представлена гистограмма, демонстрирующая разницу между фактической и прогнозируемой нейросетью стоимостью случайно отобранных 70 квартир из тестирующего множества.



Рисунок 1. Результат тестирования нейронной сети

Из результатов, изображенных на рисунке 1, можно сделать вывод об адекватной работе спроектированной нейронной сети.

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рисунке 2.




Рисунок 2. Значимость входных параметров нейросетевой модели

Как видно из рисунка 2, наиболее значимыми являются общая площадь квартиры, жилая площадь, площадь кухни, далее следуют курс доллара, цена

на нефть и т.д. Также на графике можно видеть ряд параметров, которые имеют нулевую значимость, такие как индекс города, год, ВВП в текущих ценах и др. Это можно объяснить тем, что на текущем собранном множестве для Нижнего Новгорода, данные параметры имеют одинаковое значение.

Также были рассчитаны коэффициенты корреляции Пирсона между входными параметрами модели и выходным (стоимостью квартир). Результат расчета представлен на рисунке 3 в виде гистограммы.




Рисунок 3. Значения модулей коэффициентов корреляции Пирсона между входными параметрами и стоимостью квартир

Сравнивая рисунки 2 и 3, можно заметить различия, например, между курсом доллара, ценой на нефть и стоимостью квартиры нет линейной зависимости. Расчет значимости с помощью программы «Нейросимулятор 5» позволил выявить влияние данных параметров на стоимость квартиры.

Далее было проведено исследование жилищного рынка г. Нижний Новгород. Исследование производилось с помощью метода «замораживания» [9], суть которого заключается в варьировании значения одного параметра и фиксации значений всех других параметров. Данный метод позволяет выявить влияние исследуемого параметра на выходной. Для этой цели были отобраны 5 квартир, информация о параметрах которых отражена в таблице 1.

Таблица 1 – Характеристики квартир, выбранных для исследования

№ квартиры	1	2	3	4	5
X1	8	8	8	8	8
X2	56,31049	56,31914	56,301	56,31521	56,33802
X3	44,03729	43,9511	44,0792	43,98701	43,91472
X4	1	3	4	7	6
X5	1	2	3	4	5
X6	12	2	11	1	5
X7	17	2	16	2	10
X8	54	50	101,4	73	125
X9	25	43	70	48,4	94
X10	12,5	7	16,2	10	10
X11	2	1	2	1	2
X12	2020	2020	2020	2020	2020
X13	71,9065	63,9798	71,9065	63,9798	71,9065
X14	2771,69	3574,04	2771,69	3574,04	2771,69
X15	109361,5	109361,5	109361,5	109361,5	109361,5
X16	1409,9	1409,9	1409,9	1409,9	1409,9
X17	50169	50169	50169	50169	50169

На рисунке 4 показан график зависимости стоимости квартир от количества комнат. Как следует из графика, увеличение количества комнат в квартире, не приводит к росту ее стоимости, а даже наоборот, может наблюдаться ее снижение.




Рисунок 4. Зависимость стоимости квартир Нижнего Новгорода от количества комнат

На рисунках 5-6 продемонстрирована зависимость стоимости квартир от общей площади и жилой площади соответственно. В обоих случаях прослеживается тенденция к увеличению стоимости квартир, от увеличения общей площади, жилой площади. Причем влияние общей площади на стоимость квартир более выраженное.




Рисунок 5. Зависимость стоимости квартир Нижнего Новгорода от общей площади




Рисунок 6. Зависимость стоимости квартир Нижнего Новгорода от жилой площади

Далее аналогичным методом было проведено исследование наиболее значимых макроэкономических и географических параметров.

На рисунке 7 изображен график зависимости стоимости квартиры от географической координаты – широты (долгота в данном случае остается исходной). Изменение широты влияет на местоположение квартиры в целом. Для каждой квартиры были подобраны 3 значения широты так, что местоположение каждой квартиры смещается к центру и к окраинам города. Центральная точка на каждом ряде графика отражает квартиру наиболее приближенную к центральной части города по сравнению с остальными. Как видно из графика, стоимость квартиры, расположенной ближе к центральной части города преимущественно выше.




Рисунок 7. Зависимость стоимости квартир Нижнего Новгорода от географической широты

На рисунке 8 продемонстрирован график зависимости стоимости квартир от цены на нефть. Как видно из графика, увеличение цены на нефть, приводит к снижению стоимости квартир.




Рисунок 8. Зависимость стоимости квартир от цены на нефть

Полученные результаты исследований не противоречат реальности, что подтверждает, что спроектированную нейронную сеть можно считать пригодной для прогнозирования стоимости квартир вторичного рынка Нижнего Новгорода.

Заключение. Построена система нейросетевого оценивания стоимости квартир вторичного рынка для г. Нижний Новгород. Спроектированная нейросетевая модель учитывает три категории показателей, влияющих на стоимость квартиры: строительные, географические, макроэкономические. Проведены исследования рынка жилой недвижимости Нижнего Новгорода. Методом сценарного прогнозирования построены графики зависимостей стоимости квартир от количества комнат, размера общей и жилой площади, от местоположения квартиры посредством изменения географической широты, а также от цены на нефть. Применение такого набора параметров в модели позволяет учитывать экономическую обстановку с течением времени, а также может быть в дальнейшем расширена для прогнозирования стоимости квартир для нескольких городов.

Благодарность. Работа выполнена при поддержке гранта РФФИ 19-010-00307 «Разработка интеллектуальной самоадаптируемой системы массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости регионов РФ».

Библиографический список

1. Tay D. P., Ho D. K. Artificial intelligence and the mass appraisal of residential apartments // *Journal of Property Valuation and Investment*. 1991. Vol. 10, no 2. P. 525–540.
2. Evans A., James H., Collins A. Artificial neural networks: An application to residential valuation in the UK // *Journal of Property Valuation and Investment*. 1991. no 11(2). P. 195–204.
3. Borst R.A. Artificial neural networks in mass appraisal // *Journal of Property Tax Assessment & Administration*. 1995. Vol. 1, no 2. P. 5–15.
4. Ясницкий Л.Н., Ясницкий В.Л. Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости жилых объектов на примере рынков недвижимости Екатеринбурга и Перми // *Имущественные отношения в Российской Федерации*. 2017. № 3(186). С. 68-84.
5. Yasnitsky L.N., Yasnitsky V.L. Technique of design of integrated economic and mathematical model of mass appraisal of real estate property by the example of Yekaterinburg housing market // *Journal of Applied Economic Sciences*. Winter 2016. Volume XI. Issue 8(46). Pp. 1519-1530.
6. Ясницкий Л.Н., Ясницкий В.Л. Методика создания комплексной экономико-математической модели массовой оценки стоимости объектов недвижимости на примере квартирного рынка города Перми // *Вестник Пермского университета. Сер. «Экономика»* = *PermUniversityHerald. Economy*. 2016. № 2(29). С. 54–69. doi: 10.17072/1994–9960–2016–2–54–69.

7. Корекова М.А., Нилидина Е.А., Ясницкий Л.Н. Динамическая нейросетевая система оценки вторичного рынка жилой недвижимости города Екатеринбурга // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всероссийской научно-практической конференции (г. Пермь, 21-23 мая 2019) Часть I. / Пермский государственный национальный исследовательский университет – Пермь, 2019. – С. 102-111.
8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
9. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

DYNAMIC NEURAL NETWORK SYSTEM FOR EVALUATING THE SECONDARY MARKET OF RESIDENTIAL REAL ESTATE OF THE CITY OF NIZHNY NOVGOROD

Minin Andrey S., Yasnitsky Leonid N.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

The article describes the development of a dynamic neural network system for predicting the value of residential real estate in the secondary market for Nizhny Novgorod. The system allows people to evaluate the cost of apartments based on geographical, construction and macroeconomic indicators. The use of macroeconomic parameters made it possible to make it adaptable to the current economic situation.

Key words: artificial intelligence, neural network technologies, secondary apartment market, self-adaptation, cost estimation, forecasting, residential real estate.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ СТОИМОСТИ КВАРТИР ПЕРМИ

Усанин Александр Сергеевич

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15

В статье приведены результаты проектирования и разработки системы оценки стоимости квартир города Перми. При прогнозировании цен система учитывает полную характеристику дома, в котором располагается квартира. Были проведены исследования о необходимости введения параметра удаленности квартиры от центра города. Было изучено, как будет меняться стоимость квартиры в зависимости от дома, в котором она находится.

Ключевые слова: искусственный интеллект, нейросетевые технологии, вторичный рынок квартир, оценка стоимости, прогнозирование, жилая недвижимость.

Введение. Многие российские и зарубежные исследователи пытались решить задачу массовой оценки недвижимости с помощью нейронных сетей.

В России первой нейросетевой системой оценки рынка недвижимости стала система, созданная в 2008 году сотрудниками Пермского университета [1]. В работе использовался многослойный перцептрон, сгенерированный с помощью нейропакета [8]. Полученная система, обеспечивала оценку квартир г. Перми с максимальной относительной ошибкой 16,4%. В качестве входных параметров модели использовались площадь квартиры, ее состояние, этаж, тип дома, удаленность от центра.

Проанализировав работы [2-4], можно сказать, что в них были проведены подробные исследования в области прогнозирования цен на недвижимость. В этих статьях использовались в большей степени общие экономические и социальные характеристики для прогнозирования цен на недвижимость, а в меньшей степени строительные характеристики недвижимости.

В приведенных выше работах информация о квартире бралась только из самого объявления, которая не содержит данных о доме, в котором она располагается. В связи с этим было принято решение расширить набор входных параметров информацией из открытой базы паспортных характеристик домов РФ.

Данная работа включает в себя построение интеллектуальной системы для оценки стоимости недвижимости в городе Перми с учетом характеристик квартиры, а также самого дома.

В результате анализа работ [1-4] были выделены следующие параметры, которые максимально влияют на стоимость квартиры. Это: X1 – Количество комнат (0, если студия или свободная планировка); X2 – Площадь квартиры общая (кв. м.); X3 – Площадь квартиры жилая (кв. м.); X4 – Площадь кухни квартиры (кв. м.); X5 – Этаж, на котором находится квартира (кв. м.); X6 – Широта; X7 – Долгота; X8 – Тип дома (1 – кирпичный, 2 – монолитный, 3 – панельный, 4 – блочный, 5 – деревянный); X9 – Расстояние до центра города (вычисляется как расстояние между двумя точками).

За центр города была взята точка, которую сервис Яндекс Карты выдает при поиске города Перми (центр эспланады). Пренебрегая неровностью Земной поверхности, были произведены расчеты по формуле расстояния между двумя точками:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

В качестве характеристик дома были выбраны те, которые доступны для большинства домов. Получились следующие характеристики: X10 – Нежилая площадь дома (кв. м.); X11 – Площадь общих помещений (кв. м.); X12 – Площадь парковки (кв. м.); X13 – Площадь земельного участка (кв. м.); X14 – Количество лифтов; X15 – Год постройки; X16 – Аварийность (1 – дом признан аварийным, 0 – нет); X17 – Количество этажей; X18 – Количество помещений; X19 – Жилая площадь дома (кв. м.). Выходной параметр D1 – стоимость квартиры в рублях.

Сбор данных осуществлялся с помощью программы-парсера, написанного на языке Python. На вход программе подавался список HTML-страниц сайта Avito [5], далее с помощью библиотеки BeautifulSoup [6] выполнялся анализ HTML-страниц и извлечение из их структуры необходимых данных о квартире (широта, долгота, цена квартиры и т. д.). После чего выполнялся поиск данных о доме на сайте reformagkh [7] по указанному в объявлении адресу. Собранные данные выгружались в файл в формате CSV.

Для проектирования искусственной нейронной сети была использована программа «Нейросимулятор 5» [8]. Итоговое множество составило 1156 квартир города Перми. Множество было разбито на обучающее и тестирующее в пропорции 80% и 20% соответственно. Таким образом множество тестирования составило 231 пример.

Для оценки результатов работы созданной нейронной сети, вычислялось среднее значение ошибки по формуле $\frac{E_i}{D_i} * 100\%$, где E_i – разница между фактическим и прогнозируемым значением, D_i – фактическое значение i -го тестового примера ($i=1, \dots, N$, N – размер множества).

Средняя ошибка прогнозируемой стоимости квартир для Перми на тестовом множестве составила 9.6%. А средняя ошибка в денежном эквиваленте не превышает 260 000 руб. В целом результат получился хороший. На рисунке 1 представлена гистограмма, демонстрирующая

разницу между исходными значениями выходного параметра и прогнозируемого нейронной сетью.




Рисунок 1. Результат тестирования нейронной сети, учитывающей удаленность от центра города

Таким образом была построена нейронная сеть, которая оценивает стоимость квартиры, основываясь на подробной информации о доме, в котором эта квартира располагается.

При проектировании нейронной сети для оценки стоимости недвижимости очень часто возникает вопрос – необходимо ли выделять удаленность от центра города отдельным параметром или достаточно координат самой квартиры.

Для ответа на этот вопрос была обучена еще одна нейронная сеть без параметра X8 (удаленность от центра). Результат тестирования приведен на рисунке 2.




Рисунок 2. Результат тестирования нейронной сети, не учитывающей расстояния до центра города

Средняя ошибка на тестовом множестве составила 10,9%, что является большей погрешностью, чем при введении параметра удаленности от центра. Следовательно, этот параметр влияет на точность оценки.

Далее было выполнено исследование зависимости стоимости квартиры от дома, в котором она находится. Были выбраны 4 квартиры с разными характеристиками и 4 дома, в которых они, соответственно находятся:

1. 1-комнатная квартира с общей площадью 32 кв. м. на 1 этаже. Характеристики дома: тип – кирпичный, нежилая площадь – 86,6 кв. м., площадь общих помещений – 910,5 кв. м., площадь парковки – 0 кв. м., площадь земельного участка – 2521 кв. м., количество лифтов – 0, год постройки – 1963, аварийность – нет, количество этажей – 5, количество помещений – 81, жилая площадь дома – 3155,9 кв. м.

2. 2-комнатная квартира с общей площадью 59,3 кв. м. на 16 этаже. Характеристики дома: тип – кирпичный, нежилая площадь – 0 кв. м., площадь общих помещений – 1165,4 кв. м., площадь парковки – 0 кв. м., площадь земельного участка – 0 кв. м., количество лифтов – 8, год постройки – 2015, аварийность – нет, количество этажей – 16, количество помещений – 368, жилая площадь дома – 16629,7 кв. м.

3. 3-комнатная квартира с общей площадью 75,2 кв. м. на 13 этаже. Характеристики дома: тип – панельный, нежилая площадь – 48,2 кв. м., площадь общих помещений – 2754,8 кв. м., площадь парковки – 0 кв. м., площадь земельного участка – 0 кв. м., количество лифтов – 4, год постройки – 2014, аварийность – нет, количество этажей – 20, количество помещений – 216, жилая площадь дома – 10124 кв. м.

4. 4-комнатная квартира с общей площадью 110 кв. м. на 4 этаже. Характеристики дома: тип – кирпичный, нежилая площадь – 1118,9 кв. м., площадь общих помещений – 10839,64 кв. м., площадь парковки – 0 кв. м., площадь земельного участка – 4999,2 кв. м., количество лифтов – 2, год постройки – 1997, аварийность – нет, количество этажей – 10, количество помещений – 115, жилая площадь дома – 9289,1 кв. м.

На рисунке 3 приведено расположение квартир на карте.

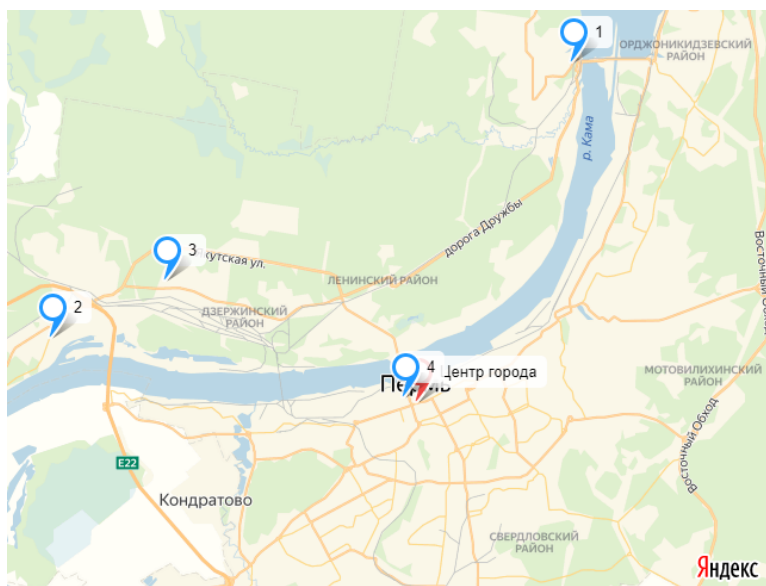


Рисунок 3. Расположение исследуемых квартир

Для начала исследуем зависимость стоимости квартиры от ее местоположения на карте и, следовательно, удаленности от центра. Характеристики дома меняться не будут. Другими словами, будем брать дом и виртуально перемещать его на карте. На рисунке 4 показана зависимость стоимости квартиры в зависимости от местоположения дома на карте. Места пронумерованы в соответствии с маркерами на рисунке 2.




Рисунок 4. Зависимость стоимости квартир от местоположения на карте

Результат получился ожидаемым – чем ближе квартира к центру, тем ее стоимость дороже. Далее проведем следующий эксперимент – будем менять дом, в котором находится квартира без изменения местоположения на карте. Если квартиры больше количества этажей в доме, то будем брать максимальный. Результаты приведены на рисунке 5.




Рисунок 5. Зависимость стоимости квартиры от характеристик дома

Можно сделать вывод, что квартиры с большой площадью имеют большую ценность в доме 1 и доме 4. Квартиры малой и средней площади больше ценятся в домах 2 и 3.

Заключение. В результате выполнения работы, было сформировано множество, содержащее информацию о квартирах, продающихся на вторичном рынке г.Перми. Также на собранных данных для Перми была спроектирована и обучена модель. Погрешность прогнозирования стоимости недвижимости данной нейронной сетью оказалась приемлема – 9,6%. Было выявлено, что удаленность от центра влияет на точность оценки, хоть и не значительно (<1,5%). На основании представленной модели было проведено исследование на предмет выявления факторов, максимально влияющих на образование цены. Выполнены исследования жилищного рынка города Перми: построены зависимости стоимости квартир от различных характеристик квартир и домов. Модель может быть полезна как для физических лиц, например, помогая рассчитать стоимость при публикации объявления о продаже или покупке, так и для юридических, например, помогая банкам оценить стоимость имущества.

Благодарность. Работа выполнена при поддержке гранта РФФИ 19-010-00307 «Разработка интеллектуальной самоадаптируемой системы массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости регионов РФ».

Библиографический список

1. Ясницкий Л.Н., Бондарь В.В., Бурдин С.Н. и др. Пермская научная школа искусственного интеллекта и ее инновационные проекты. 2-е изд. Москва-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. 75 с.
2. Корекова М.А., Нилидина Е.А., Ясницкий Л.Н. Динамическая нейросетевая система оценки вторичного рынка жилой недвижимости города Екатеринбурга // Искусственный интеллект в решении

- актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всероссийской научно-практической конференции (г. Пермь, 21-23 мая 2019) Часть I. / Пермский государственный национальный исследовательский университет – Пермь, 2019. – С. 102-111.
3. Ясницкий Л.Н., Ясницкий В.Л. Методика создания комплексной экономико-математической модели массовой оценки стоимости объектов недвижимости на примере квартирного рынка города Перми // Вестник Пермского университета. Сер. «Экономика» = Perm University Herald. Economy. 2016. № 2(29). С. 54–69. doi: 10.17072/1994–9960–2016–2–54–69.
 4. Yasnitsky L.N., Yasnitsky V.L. Technique of design for integrated economic and mathematical model for mass appraisal of real estate property. Study case of Yekaterinburg housing market // Journal of Applied Economic Sciences. 2016. 11(8). Pp. 1519-1530.
 5. Avito. Доска объявлений [Электронный ресурс]. URL: www.avito.ru (Дата обращения 24.02.2020)
 6. Beautiful Soup Documentation [Электронный ресурс]. URL: <https://www.crummy.com/software/BeautifulSoup/bs4/doc/> (Дата обращения 24.02.2020)
 7. Reformagkh. [Электронный ресурс]. URL: www.reformagkh.ru (Дата обращения 24.02.2020)
 8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

NEURAL NETWORK SYSTEM FOR EVALUATING THE COST OF PERM APARTMENTS

Usanin Aleksandr S.
Perm State University
Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

The article describes the design and development of a system for assessing the cost of apartments in the city of Perm. When forecasting prices, the system takes into account the full characteristics of the house in which the apartment is located. Studies have been conducted on the need to introduce the parameter of remoteness of the apartment from the city center. It was studied how the cost of an apartment will change depending on the house in which it is located.

Key words: artificial intelligence, neural network technologies, secondary market of apartments, valuation, forecasting, residential real estate.

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ НАЛИЧИЯ НЕРВНО-ПСИХИЧЕСКОЙ НЕУСТОЙЧИВОСТИ

Зейтунян Аким Арсенович

Пермский государственный национальный исследовательский университет,
механико-математический ф-т, ПМИ
614990, Россия, г. Пермь, ул. Букирева, 15, akim.zeytunyan@mail.ru

Разработана математическая модель, предназначенная для определения предрасположенности человека к нервно-психической неустойчивости. В основе модели лежит нейронная сеть, обученная на результатах специального опроса, в который включены вопросы о наличии основных причин нервно-психической неустойчивости у человека. Созданная модель позволяет проверить, действительно ли наличие данного недуга у человека зависит от наличия выделяемых причин, а также какие причины, являющиеся по совместительству входными параметрами нейросети, более или менее значимы. Кроме того, используя полученные в работе оценки степеней значимости входных параметров, люди с наличием исследуемой проблемы могут сделать выводы о том, что именно им необходимо предпринять, чтобы избавиться от нее.

Ключевые слова: искусственный интеллект, нейронная сеть, закономерности, прогнозирование, нервно-психическая неустойчивость.

Введение. Нервно-психическая неустойчивость – склонность к срывам нервной системы при значительных физических и психических нагрузках [1. с 8]. Характеризуется эмоциональной неустойчивостью, тревогой, низким самоуважением, вегетативными расстройствами. Нервно-психическую неустойчивость не следует отождествлять с неврозом [2. с 253].

По данным РАМН в России 5 миллионов человек страдают тяжелыми психическими заболеваниями. Еще четверть населения – то есть 36,5 миллионов человек – страдают различными психическими расстройствами. Еще 10 лет назад эта цифра была в 2,5 раза ниже. Сегодня в мире только 10% людей – стрессоустойчивые. В обычной жизни 25% населения сталкиваются с проблемами в плане психического здоровья, каждый четвертый человек нуждается в помощи психотерапевтов, специалистов в области неврологии, психологов, хотя многие даже и не подозревают об этом [3. с 3]. Проблема состоит в том, что количество людей с нервно-психической неустойчивостью продолжает расти, а процент здоровых людей, соответственно, начинает снижаться.

Цель работы заключается в применении методов искусственного интеллекта в предсказании наличия у людей признаков НПН, а,

следовательно, и в возможности дать людям своевременный «сигнал», благодаря которому они смогут предпринять меры по ее профилактике.

Нейронные сети в психодиагностике. В настоящее время нейронные сети успешно используются в научных исследованиях. С момента их появления они доказали свою эффективность в решении широкого спектра задач, связанных с распознаванием образов, классификацией, принятием решений, адаптивным управлением, кластеризацией, прогнозированием, аппроксимацией, сжатием данных и ассоциативной памятью [6].

Благодаря внедрению информационных технологий в психологическую науку появилась возможность решения задач практической психологии с помощью нейронных сетей. Важное место в современной психологии отводится психодиагностике – отрасли психологии, целью которой стоит измерение индивидуально-психологических особенностей личности, их оценка. В современной науке нейросети применяются во многих психодиагностических исследованиях. Так, например, Пермским отделением Научного Совета РАН по методологии искусственного интеллекта получены положительные результаты в создании интеллектуальных систем, предназначенных для диагностики сердечно-сосудистых заболеваний [7], выявления склонности к насилию [8], к депрессии [9], к алкогольной зависимости [10], к наркозависимости [11], выявления признаков лжи [12-14] выявления у человека скрытых талантов, способностей [9, 10].

Методика. Для построения, обучения и тестирования нейросетевой математической модели были задействованы результаты опроса, в который была включена общая информация об опрашиваемых (пол, возраст), вопросы о наличии у опрашиваемых всех основных причин наличия НПН. Также в опрос был включен результирующий вопрос, в котором опрашиваемому было дано определение НПН, и спрашивалось о её наличии. На основании ответа на этот вопрос и ставился соответствующий диагноз. То есть данные анкет использовались как в качестве входных, так в качестве и выходных параметров нейросетевой математической модели. Опрос был размещен на веб-сервисе для создания опросов и сбора ответов (URL: <http://anketolog.ru>), а также был распространен среди обучающихся Пермского государственного национального исследовательского университета. Общее количество анкетированных составило 150 человек. В качестве входных параметров нейросетевой модели были приняты следующие факторы:

- x_1 – Пол:
 - мужской; 2 – женский.
- Возраст.
- x_3 – Образование:
 - 1 – неполное среднее; 2 – среднее/среднее специальное; 3 – неполное высшее; 4 – высшее.
- x_4 – Тип темперамента:
 - сангвиник; 2 – флегматик; 3 – холерик; 4 – меланхолик.
- x_5 – Тип мышления:
 - технический; 2 – гуманитарный.
- x_6 – Подверженность в детстве «гиперопеке» со стороны родителей/родственников:

1 – был подвержен в большом количестве; 2 – был подвержен в умеренном количестве; 3 – не был подвержен.

x_7 – Наличие психических отклонений, таких как частые депрессивные состояния, неврозы, нервные тики, маниакальные расстройства:

1 – да; 2 – нет.

x_8 – Рос в полной семье:

1 – да; 2 – нет, рос без отца; 3 – нет, рос без матери; 4 – нет, рос без родителей.

x_9 – Наличие хронических заболеваний:

1 – да; 2 – нет.

x_{10} – Правильное питание:

1 – да; 2 – пытаюсь правильно питаться, но у меня не всегда это выходит; 3 – редко правильно питаюсь; 4 – нет.

x_{11} – Подвергался психологическим травмам, в т. ч. насильственного физического и/или психологического характера:

1 – да; 2 – нет.

x_{12} – Наличие проблем, которые не с кем обсудить:

1 – да; 2 – нет.

x_{13} – Трудно знакомиться с новыми людьми:

1 – да; 2 – нет.

x_{14} – Знакомых в интернете больше, чем в реальной жизни:

1 – да; 2 – нет.

Выходной параметр нейросети у есть результат прогноза: 1 – наличие нервно-психической неустойчивости; 2 – отсутствие нервно-психической неустойчивости.

Количество входных параметров (в нашем случае их 14) есть количество входных нейронов проектируемого персептрона. Аналогично, на выходном слое в нашем случае будет всего один нейрон.

Согласно теоремам Арнольда-Колмогорова-Хехт-Нильсена в нейронной сети персептронного типа должен быть как минимум один скрытый слой. Экспериментальным путем было выявлено, что оптимальная модель сети в нашем случае должна содержать ровно один скрытый слой с пятью нейронами на нем. Итоговая структура нейронной сети представлена на рис. 1.




Рисунок 1. Полученная нейронная сеть

Так как проектируемая нейросеть должна не только правильно реагировать на примеры, на которых она обучена, но и уметь обобщать приобретенные знания, т. е. правильно реагировать на примеры, которых в обучающем множестве не было [4. с 115], множество полученных результатов опроса, то есть множество примеров поведения предметной области, было разделено на два подмножества: обучающее и тестирующее. В обучающее множество попало 135 анкет (90% от общего количества), остальные 15 (10%) составили тестирующее множество.

Проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью выполнялись с помощью нейросимулятора [5].

Путем множества попыток обучения нейросети получилось прийти к случаю, в котором квадратичная ошибка обучения составляла лишь 2,96 %.

После обучения нейросети она проверялась на примерах тестового множества. Результаты проверки приведены на рис. 2. Квадратичная ошибка тестирования (обобщения) составила 15 %.




Рисунок 2. Сравнение показателей НПН и предсказаний нейросети

Как мы видим, построенная нейросеть успешно выявляет степень нервно-психической неустойчивости у большинства тестируемых. То есть мы можем утверждать, что она усвоила общие закономерности моделируемой предметной области. Однако, внедрять такую модель в серьезную деятельность, например, в промышленность или в работу врачей-специалистов не стоит, ведь, как мы можем заметить, в двух из пятнадцати случаев (№3, №14) нейросеть предсказала противоположный результат. Если бы данную модель использовали при постановке диагноза, то в двух случаях из пятнадцати врач бы поставил неверный диагноз. В столь важных сферах мы не можем себе позволить использовать средства, дающие результат с такой погрешностью. Причина этой погрешности заключается в недостаточном соответствии опроса реальным причинам нервно-

психической неустойчивости, а также в недостаточном количестве этих причин. Очевидно, что психологами выделяется куда больше причин возникновения НПН, по сравнению с четырнадцатью, рассмотренными в этой работе.

Вычислительные эксперименты и обсуждения результатов. Разработанная нейросеть проверена на адекватность результатов. Теперь мы можем приступить к её исследованию и выявлению новых закономерностей. Первым делом выясним значимость каждого из входных параметров модели. Для этого воспользуемся опцией нейросимулятора [5], позволяющей вычислить эту значимость и сразу представляющей полученные результаты в виде гистограммы. Полученная гистограмма представлена на рис. 3.




Рисунок 3. Гистограмма распределения значимости входных параметров математической модели

Как мы видим, наименее значимым входным параметром оказался пол, а значит наличие нервно-психической неустойчивости у человека, среди всех вышеуказанных параметров, в меньшей степени зависит от его пола. Наиболее значимыми параметрами оказались следующие:

- Больше количество знакомых в интернете, чем в реальной жизни;
- Затруднения в знакомствах с новыми людьми;
- Наличие проблем, которые не с кем обсудить;
- Наличие психологических травм.

Первые три наиболее значимых параметра определенно дают понять, что нервно-психическая неустойчивость возникает в основном у одиноких, не уверенных в себе людей.

Следующим шагом мы исследуем каким образом на наличие нервно-психической неустойчивости влияют изменения входных параметров. На рис. 4 приведены результаты экспериментов, выполненных для человека со следующими параметрами:

- Пол: мужской;
- Возраст: 24 года;
- Образование: высшее;
- Тип темперамента: флегматик;
- Тип мышления: гуманитарный;
- Подверженность гиперопеке: в умеренных количествах;
- Наличие психических отклонений: отсутствуют;
- Рос в полной семье: да;
- Наличие хронических заболеваний: присутствуют;
- Питание: не всегда правильное;
- Психологические травмы: отсутствуют;
- Проблемы, которые не с кем обсудить: отсутствуют;
- Трудно знакомиться с людьми: да;
- Больше количество знакомых в интернете, чем в жизни: нет;

На рис. 4 единица по оси «Наличие НПН» означает абсолютную уверенность нейросетевой модели в отсутствии у объекта нервно-психической неустойчивости, а двойка, соответственно, абсолютную уверенность в её присутствии.




Рисунок 4. Зависимость наличия НПН у мужчины от его возраста и типа темперамента

Из рис. 4 можно сделать вывод, что у всех лиц мужского пола с возрастом от 24-х до 56-и лет и с меланхоличным типом темперамента с очень большой вероятностью наблюдаются признаки НПН. Кроме того, у лиц с типами темперамента, отличными от сангвиников, до сорока лет эта вероятность растет, а после сорока – убывает. У сангвиников же, как показывает спроектированная модель, вероятность наблюдения НПН отсутствуют вообще.

Попробуем провести такое же исследование для лица женского пола и посмотрим изменится ли результат в этом случае. Все остальные параметры идентичны набору параметров предыдущего эксперимента. Результат представлен на рис. 5.




Рисунок 5. Зависимость наличия НПН у женщины от ее возраста и типа темперамента

Как видно из рис. 5, высокие шансы на наличие НПН наблюдаются лишь у женщин в молодом возрасте. Аналогично предыдущему эксперименту, больше всего женщин с НПН имеют меланхолический тип темперамента, а у сангвиников, опять же, шансы на НПН отсутствуют вообще.

Теперь исследуем зависимость наличия НПН от возраста и правильности питания. В качестве примера возьмем следующие параметры:

- Возраст: 20 лет;
- Образование: среднее;
- Тип темперамента: холерик;
- Тип мышления: гуманитарный;
- Подверженность гиперопеке: в умеренных количествах;
- Наличие психических отклонений: присутствуют;

- Рос в полной семье: нет, рос без отца;
- Наличие хронических заболеваний: отсутствуют;
- Питание: редко правильное;
- Психологические травмы: присутствуют;
- Проблемы, которые не с кем обсудить: присутствуют;
- Трудно знакомиться с людьми: нет;
- Больше количество знакомых в интернете, чем в жизни: нет;

На рис. 6 представлен результат для мужчины, на рис. 7 – для женщины.




Рисунок 6. Зависимость наличия НПН у мужчины от его возраста и питания

Как мы видим, у нас получаются довольно неожиданные результаты. Нейросетевая модель показывает, что у с увеличением степени правильности питания и возраста у мужчин, у них возрастает и шанс наличия НПН, причем при абсолютно правильном питании этот шанс максимален, а при абсолютно неправильном его нет вообще.




Рисунок 7. Зависимость наличия НПН у женщины от ее возраста и питания

При выполнении того же эксперимента для лица женского пола мы получаем похожие результаты за исключением того, что у женщин шанс наличия НПН растет не при увеличении возраста, а при его уменьшении. То есть мы еще раз убеждаемся, что женщины в молодом возрасте более подвержены срывам нервной системы. Однако, самым интересным является то, что как женщины, так и мужчины, не придерживающиеся принципов правильного питания, по мнению нейросети, совершенно не склонны к НПН.

Как мы видим, путем исследования построенной нейросети мы получаем определенные закономерности, знания, которые без нее мы вряд ли бы заметили. Это подтверждает то, что методы искусственного интеллекта, нейросетевые технологии, в частности, являются незаменимым инструментом для построения систем извлечения знаний из данных [4. с 25].

Заключение. Разработана нейросетевая математическая модель, предназначенная для определения у человека наличия нервно-психической неустойчивости. С ее помощью построены зависимости НПН от пола, возраста, типа темперамента, правильности питания. Установлено, что все перечисленные параметры являются значимыми.

Модель и эксперименты, проводимые с ней, могут быть использованы для определения действий, которые необходимо предпринять для профилактики нервно-психической неустойчивости, и действий, которых надо избежать, чтобы её формы не появились.

Библиографический список

1. Баймухамбетова Б.Ш., Жусупова Ж.Ж. Понятие «Нервно-психическая неустойчивость» в психологической науке // Вестник КГПИ, Серия «Психология». – Костанай, 2009. – Вып. 2. – С. 8-13.
2. Александровский Ю.М. Пограничные психические расстройства. – Спб: Питер, 2006.

3. Берг Т.Н. Нервно-психическая неустойчивость и способы ее выявления. – Владивосток: Мор. гос. ун-т, 2005. – 63 с.
4. Ясницкий Л.Н. Интеллектуальные системы / Лаборатория знаний, 2016. – 221 с.
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
6. Хайкин С. Нейронные сети: Полный курс. – Изд. 2-е. – М.: Вильямс, 2006 – 1101 с.
7. Ясницкий Л.Н., Думлер А.А., Полещук А.Н., Богданов К.В., Черепанов Ф.М. Нейросетевая система экспресс-диагностики сердечно-сосудистых заболеваний // Пермский медицинский журнал. – 2011. – №4. – С. 77-86.
8. Yasnitsky, L.N., Vauleva, S.V., Safonova, D.N., Cherepanov, F.M. The use of artificial intelligence methods in the analysis of serial killers' personal characteristics // Criminology Journal of Baikal National University of Economics and Law. 2015. 9 (3), pp. 423-430. DOI: 10.17150/1996-7756.2015.9(3). 423-430.
9. Левченко Е.В., Митрофанов И.А., Ясницкий Л.Н. Нейросетевое моделирование феномена депрессии // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Третьей всерос. науч.-практ. конф. (г. Пермь, 14–18 мая 2018 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2018. – С. 139-143.
10. Ясницкий Л.Н., Гилевский А.С., Радостев Д.А., Рычина Е.В., Черепанов Ф.М. Нейросетевая система диагностики и нивелирования предрасположенности к алкогольной зависимости // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. Научн.-прокт. конф. (г.Пермь, 17-19 мая 2016 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2016. С. 201 – 207.
11. Ясницкий Л.Н., Грацилев В.И., Куляшова Ю.С., Черепанов Ф.М. Возможности моделирования предрасположенности к наркозависимости методами искусственного интеллекта. // Вестник Пермского университета. Серия: Философия. Психология. Социология. 2015. № 1(21). С. 61-71.
12. Петров А.М., Ясницкий Л.Н. Возможности создания нейросетевого полиграфа. Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2005. № 2. С.43-47.
13. Ясницкий Л.Н., Петров А.М., Сичинава З.И. Технологии построения детектора лжи на основе аппарата искусственных нейронных сетей // Информационные технологии. – 2010. – № 11. – С. 66-70.
14. Ясницкий Л.Н., Сичинава З.И., Черепанов Ф.М. Нейросетевой детектор лжи: принципы построения и опыт разработки. – Saarbrucken (Germany): LAP LAMBERT Academic Publishing GmbH & Co. KG., 2012. – 115p

15. Ясницкий Л.Н., Байдин Д.Ю., Макурина Т.В., Черепанов Ф.М.
Возможности выявления способности людей к научной деятельности методами искусственного интеллекта // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. Научн.-практ. конф. (г.Пермь, 17-19 мая 2016 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2016. С. 193 – 200.
16. Байдин Д.Ю. Определение способности к научной деятельности с помощью нейронных сетей // Искусственный интеллект: философия, методология, инновации. Сборник трудов VII Всероссийской конференции студентов, аспирантов и молодых ученых. Часть 2. г. Москва, МГТУ МИРЭА, 13-15 ноября 2013 г. – М.: «Радио и Связь», 2013. – С. 10-15.

NEURAL NETWORK FORECASTING THE PRESENCE OF NEUROPSYCHIATRIC INSTABILITY

Zeytunyan Akim A.

Perm State University

614990, Russia, Perm, street Bukireva, 15, akim.zeytunyan@mail.ru

This article describes the development of a mathematical neural network model designed to determine a person's predisposition to neuropsychiatric instability. The model is based on a neural network trained on the results of a special survey, which includes questions about the presence of the main causes of neuropsychiatric instability in humans. The created model allows you to check whether the presence of this disease in a person depends on the presence of the selected causes, as well as which causes, which are also input parameters of the neural network, are more or less significant. In addition, based on the degree of significance of the input parameters, people with the presence of the problem under study can draw conclusions about what they need to do to get rid of it.

Key words: artificial intelligence, neural network, regularities, forecasting, neuro-mental instability.

САМОАДАПТИРУЕМАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ КАЧЕСТВА ПИТАНИЯ ЧЕЛОВЕКА

Вотинова Елизавета Сергеевна, Филатова Полина Денисовна
Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул.Букирева, 15

В статье представлено описание разработки нейросетевой системы для оценки качества питания человека. Система позволяет оценку качества по характеристикам самого человека и его питания. Было проведено ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: нейронная сеть, качество питания, калории, БЖУ.

Введение. В свое время великий медик Гиппократ сказал: «Мы есть то, что мы едим». Действительно, пища влияет на самочувствие человека, на его состояние здоровья и настроение. Для того, чтобы развиваться и обновляться, клеткам нашего организма нужно питание. Главное условие правильного питания – это его сбалансированность. Важно не только количество потребляемых калорий, но и распределение этого питания на белки, жиры и углеводы (БЖУ). У каждого из нас есть суточная норма калорий, суточная норма потребления БЖУ. Большинство не уделяют должного внимания полноценному и рациональному питанию: кто-то переедает, кто-то недоедает. Все это через время сказывается на организме. Поэтому очень важно знать ответ на вопрос: а правильно ли я питаюсь? насколько правильно мое питание?

Любому человеку полезно знать о качестве своего питания. Данная информация поможет оценить сбалансированность и предпринять дальнейшие действия по улучшению результата. Поэтому данная тема достаточно актуально, а значит есть смысл разработать математическую модель на основе нейронной сети, которая бы дала оценку питания.

Сейчас существуют несколько формул для правильного расчета калорий и БЖУ. Для расчета калорий использовала наиболее популярная формула – формулу Харриса-Бенедикта. Нормальное количество белков и жиров рассчитывается по весу человека. Так на 1 кг веса необходимо примерно 0,75-2,5 г белка и 0,7-2 г жиров. Углеводы же занимают оставшееся от общего количества калорий. Расчет нормы калорий производится по следующим формулам:

- Для мужчин

$$BWR = 88.36 + (13.4 * \text{вес, кг}) + (4.8 * \text{рост, см}) - (5.7 * \text{возраст, лет}) \quad (1)$$

$$\text{Норма калорий} = \text{BMR} * \text{Уровень активности} \quad (2)$$

- Для женщин

$$\text{BWR} = 447.6 + (9.2 * \text{вес, кг}) + (3.1 * \text{рост, см}) - (4.3 * \text{возраст, лет}) \quad (3)$$

$$\text{Норма калорий} = \text{BMR} * \text{Уровень активности} \quad (4)$$

В результате анализа литературных источников [3]-[7] был выбран следующий набор показателей: X1 – пол, X2 – возраст, X3 – вес, X4 – рост, X5 – активность, X6 – калории, X7 – белки (г), X8 – жиры (г), X9 – углеводы (г). Выходной параметр D1 – качество питания.

Параметр пол был закодирован: 0 – мужчина, 1 – женщина. Параметр активности был закодирован 1,2 – минимальный, 1,375 – низкий, 1,55 – средний, 1,725 – высокий уровень, 1,9 – очень высокий.

Оценка качества питания и кодировка выходного параметра производятся следующим образом:

1. Если количество калорий не соответствует норме калорий для этого человека, то качество питания равно 0 – низкое (допускается погрешность в 150 ккал).

2. Если количество калорий попадает в диапазон нормы для этого человека, но показатели БЖУ не сбалансированы, то качество питания 0.5 – среднее.

3. Если количество калорий попадает в диапазон нормы и показатели БЖУ сбалансированы, то качество питания равно 1 – высокое.

Множество наборов данных о людях и их питании было составлено самостоятельно. Перед переходом к проектированию и обучению нейросетевой модели, была выполнена проверка исходного множества на дубликаты. Чтобы не допустить некорректные примеры для вычисления всех данных использовались созданные в начале работы формулы. Таким образом, объем итогового множества включает в себя 517 примеров. Данное множество было разделено на обучающее и тестирующее в соотношении примерно 80% и 20% соответственно.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [1]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет девять входных нейронов, один выходной и два скрытых слоя с шестью нейронами на каждом слое.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 112 примеров. Средняя ошибка тестирования составила 17.8%. На рисунке 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью качеством питания.




Рисунок 1 – Результат тестирования нейронной сети

На рисунке 2 представлена гистограмма, показывающая распределение значимости параметров.

Самым значимым входным параметром оказалось количество калорий, следующими по значимости оказались количество углеводов, активность и вес респондента, наименьшую значимость имело количество употребляемых белков. Абсолютно неэффективных входных параметров не оказалось.

Таким образом, была спроектирована самоадаптируемая нейросеть, предназначенная для оценки качества питания граждан.




Рисунок 2 – Значимость параметров

Далее было выполнено исследование ответов пяти случайно выбранных респондентов, имеющих разные физические параметры. Исследование производилось с помощью метода «замораживания». Его суть

– в изменении значения одного из параметров и фиксирования всех остальных. С его помощью можно понять, как именно исследуемый параметр влияет на значение выходного параметра.

Таблица 1 – Основные характеристики опрошенных

Параметры	Респондент 1	Респондент 2	Респондент 3	Респондент 4	Респондент 5
Пол	1	0	0	1	1
Возраст	16	50	20	30	39
Вес	50	88	55	62	52
Рост	160	190	162	168	168
Активность	1,2	1,55	1,725	1,375	1,9
Калории	1600	2300	2500	2000	2400
Белки	80	30	40	90	100
Жиры	50	50	60	90	100
Углеводы	197	418	434	194	259
Качество питания	1	0	0,5	1	0,5

На рисунке 3 показан график зависимости качества питания от возраста респондента.




Рисунок 3 – Зависимость качества питания от возраста

На рисунках 4 продемонстрирована зависимость качества питания от пола респондента.




Рисунок 4 – Зависимость качества питания от пола

На рисунке 5 представлено зависимость качества питания от количества калорий. Было замечено, что с увеличением числа калорий качество питания уменьшается. Действительно, оптимальное количество калорий находится в диапазоне 1200-4000 ккал в зависимости от других характеристик человека, не учитывая особенности организма, заболевания, целенаправленную деятельность человека (набор мышечной массы, сушка).




Рисунок 5 – Зависимость качества питания от потребляемых калорий

На рисунке 6 изображен график зависимости качества питания от количества потребляемых углеводов, где так же было отмечено снижение качества питания при увеличении количества углеводов.




Рисунок 6 – Зависимость качества питания от количества потребляемых углеводов

На рисунке 7 продемонстрирован график зависимости качества питания от степени активности респондента.




Рисунок 7 – Зависимость качества питания от степени активности

Полученные результаты исследований не противоречат реальности, что подтверждает, что спроектированную нейронную сеть можно считать пригодной для определения качества питания.

Заключение. Спроектирована и построена система нейросетевого оценивания качества питания людей. Проведены исследования в области правильного, сбалансированного питания, влияющего на образ, а главное, качество жизни. Методом сценарного прогнозирования построены графики зависимостей качества питания от количества потребляемых калорий, степени активности, количества потребляемых углеводов человека. Данная нейросетевая модель может быть использована для улучшения образа жизни человека путем выявления проблем в области употребления пищи, а также может быть в дальнейшем расширена для определения способов корректировки питания с целью похудения/набора мышечной массы и т.д.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
3. . Плискина Ю. В. Счетчик калорий. Основы правильного питания. М.: Эксмо-Пресс, 2017. – 192 с.
4. Максименко А., Кудерова Ю., Кудеров М. Книга зожника. М.: Манн, Иванов и Фербер, 2019. – 224 с.
5. FITSEVEN. – URL: <https://fitseven.ru/zdorovie/metabolism/sutochnaya-no>
6. EDATOR. – URL: <https://edator.ru/252-raschet-bzhu.html>
7. NaDiety.Net. – URL: <https://nadietu.net/micronutrients/1-gramm.html>

SELF-ADAPTIVE NEURAL NETWORK EVALUATION SYSTEM QUALITY OF HUMAN NUTRITION

Votnova Elizaveta Sergeevna, Filatova Polina Denisovna.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990

The article describes the development of a neural network system for evaluating the quality of human nutrition. The system allows you to evaluate the quality of the characteristics of the person and their nutrition. A number of studies have been conducted, the results of which are presented in this article.

Keywords: neural network, nutrition quality, calories, PFC.

ПРОГНОЗИРОВАНИЕ ПОЛЬЗОВАТЕЛЬСКОГО РЕЙТИНГА МОБИЛЬНЫХ ПРИЛОЖЕНИЙ

Ракова Анна Сергеевна

Национальный исследовательский университет «Высшая школа экономики»,
Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38,
as.rakova@yandex.ru

На базе нейронной сети разработана математическая модель, прогнозирующая пользовательский рейтинг мобильных приложений, на основе их основных характеристик. С помощью анализа математической модели выявлены наиболее значимые характеристики, влияющие на рейтинг мобильных приложений. Выявлены основные жанры приложений, которые получают наиболее высокий пользовательский рейтинг.

Ключевые слова: мобильные приложения, пользовательский рейтинг, прогнозирование, нейронная сеть.

С каждым годом процент продаж мобильных телефонов неуклонно растет, а это влечет за собой и увеличение спроса на мобильные приложения. Пока одни компании создают небольшие программы для удобства своих клиентов, другие зарабатывают на производстве мобильных приложений. По данным статистики за первую половину 2019 года программы из App Store и Google Play в сумме заработали \$39,7 млрд, что на 15,4% больше показателя 2018 года (\$34,4 млрд) [1].

Однако для того, чтобы создать приложение, которое точно получит высокий рейтинг и станет популярным, требуется предугадать, какие характеристики требуется должно иметь приложение. Поэтому целью настоящей работы является применение современных методов искусственного интеллекта для построения методики прогнозирования пользовательского рейтинга мобильных приложений на операционной системе IOS. В качестве пособий по теоретическим основам построения и применения нейронных сетей, использовались [2,3]

При постановке задачи в качестве входных параметров нейросетевой математической модели были выбраны критерии, которые являются наиболее широко распространенными для определения качества мобильных приложений. Данные были получены из приложения App Store [4]. Всего было использовано шесть характеристик:

- X1 – кол-во дней с последнего обновления версии;
- X2 – кол-во дней со дня публикации приложения;
- X3 – кол-во пользователей поставивших оценку;

- X4 – стоимость приложения (\$);
- X5 – покупки в приложении: 0 – нет, 1 – да;
- X6 – возрастное ограничение;
- X7 – основной жанр приложения.

Для каждого жанра был определен номер, которым она шифруется в выборках. Названия категорий и их номера представлены в таблице 1.

Таблица 1 – Категории приложения с номерами

1	Games	7	Food & drink	13	Productivity
2	Book	8	Health & fitness	14	Reference
3	Business	9	Lifestyle	15	Social Networking
4	Education	10	Medical	16	Sports
5	Entertainment	11	Music	17	Stickers
6	Finance	12	News	18	Utilities

С помощью нейросимулятора [5] было выполнено проектирование, оптимизация, обучение и тестирование нейронной сети. Для обучения нейронной сети было использовано 106 примеров, в тестовое множество вошли 26 примеров.

Оптимальная структура нейронной сети представляет собой персептрон, имеющий 7 входных нейронов, три скрытых слоя с 4, 3 и 3 нейронами, и 1 выходной нейрон (рис.1). В качестве активационных функций нейронов слоев использовались тангенс гиперболические функции.




Рисунок 5. Спроектированная нейронная сеть

После оптимизации и обучения нейронной сети ее прогностические свойства проверялись на примерах тестирующего множества примеров, которые в процессе обучения нейросети не участвовали. Среднеквадратичное отклонение тестирования нейронной сети составила 17,1% для прогноза пользовательского рейтинга.

Далее была проведена оценка степени достоверности прогнозируемого результата, представленная в виде гистограммы на рис. 2.




Рисунок 6. Соответствие истинных показателей и результатов работы нейронной сети

Исходя из этого, можно утверждать, что нейронная сеть усвоила закономерности моделируемой предметной области и адекватна ей.

По результатам моделирования была определена значимость параметров (рис. 3).




Рисунок 7. Диаграмма значимости параметров

На основе данных значимости параметров, вычисленных нейросетью, были выявлены несколько основных параметров:

1. Количество дней с последнего обновления версии приложения
2. Количество оценок
3. Количество дней со дня публикации приложения в магазине

4. Основной жанр игры

Возьмем, к примеру, приложение с характеристиками, представленными в таблице 2.

Таблица 5 – Характеристики для оценки рейтинга по количеству дней последнего обновления приложения

X1	X2	X3	X4	X5	X6	X7
2000	2027	153	0	1	4	1

При таких параметрах оценка приложения будет составлять 1,86. При уменьшении значения первого параметра оценка приложения также будет падать, как показано на рис. 4.




Рис. 8. Диаграмма зависимости рейтинга от количества дней со дня обновления последней версии

Далее изменим количество людей, которые выставляют оценку приложению, и будем увеличивать их на 10 человек последующую запись. Получим следующие данные, представленные на рисунке 5.



Рисунок 9. Диаграмма зависимости рейтинга от количества людей, которые оценили приложение

Как можно заметить, при увеличении пользователей, поставивших оценку приложению, увеличивается собственно сама оценка.

Возьмем другие параметры приложения, представленные в таблице 3.

Таблица 6. Характеристики для оценки рейтинга по количеству дней со дня первой публикации

X1	X2	X3	X4	X5	X6	X7
875	1634	153	0	1	4	2

При изменении параметра «количество дней со дня первой публикации» происходит также изменение самого рейтинга приложения, как представлено на рис. 6.




Рисунок 10. Диаграмма зависимости рейтинга от количества дней со дня первой публикации

При увеличении дней со дня релиза, рейтинг приложения также увеличивается.

Далее было проведено изменение жанров приложения, но при этом сохранение остальных атрибутов приложения (рис. 7).




Рисунок 11. Диаграмма зависимости среднего рейтинга от жанра приложения

Как видно из рисунка 7, наиболее высокий рейтинг получают мобильные приложения жанров: Games, Book и Business, а наименьшие – Health & fitness Lifestyle и Medical.

Библиографический список

1. Sensor Tower Quarterly Reports: [Электронный ресурс] // URL: <https://sensortower.com/reports>. (Дата обращения: 30.11.2019).
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
3. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
4. Kaggle – Mobile App Store. [Электронный ресурс] // URL: <https://www.kaggle.com/ramamet4/app-store-apple-data-set-10k-apps>. (Дата обращения: 01.12.2019).
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

FORECASTING USER MOBILE APPLICATIONS RATING

Rakova Anna S.

Perm Campus of National Research University Higher School of Economics,
614070, Russia, Perm, Studencheskaya, d. 38, as.rakova@yandex.ru

Based on the neural network, a mathematical model was developed that predicts the user rating of mobile applications based on their main characteristics. By analyzing the mathematical model, the most significant characteristics were identified that affect the rating of mobile applications. In addition, the main application genres were identified that receive the highest user rating.

Key words: mobile applications, user rating, forecasting, neural network.

РАЗРАБОТКА СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ ВРАЧЕБНЫХ РЕШЕНИЙ НА ОСНОВЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

*Перелыгин Лев Юрьевич, Столбов Валерий Юрьевич,
Мулюкин Сергей Владимирович*

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, ул. Профессора Поздеева, 13,
leoperelygin@gmail.com

Гаврилов Василий Александрович,
Пермский Государственный Медицинский Университет
614000, Россия, г.Пермь, ул. Куйбышева, 39, inmyplay@mail.ru

В статье представлено описание разработки системы поддержки принятия врачебных решений при выборе метода лечения больных с грыжами брюшной полости. Система позволяет классифицировать пациента в одну из определенных групп и прогнозировать метод лечения пациента с учетом его персональных характеристик. Реализуется два способа прогнозирования – на основе метода k-ближайших соседей и на основе нейросетевых технологий. При использовании реальных данных решена задача кластеризации и установлены четыре класса пациентов. Точность прогноза необходимого метода лечения составляет 74-76%. По мнению экспертов в области медицины для оставшейся части пациентов возможен альтернативный метод операции. Полученные результаты адекватны и могут быть применены в практической медицине.

Ключевые слова: искусственный интеллект, алгоритм k-ближайших соседей, нейросетевые технологии, абдоминальная хирургия, кластеризация, классификация, прогнозирование, грыжа брюшной полости.

Введение. Необходимость разработки экспертной системы поддержки принятия врачебных решений (СППВР) возникла в результате клинической, организационной и экономической потребностей. Данная система поможет врачам лечебных учреждений быстро сориентироваться при выборе метода лечения пациента, повышая эффективность хирургического вмешательства на основе ретроспективной базы данных о пациентах с грыжами брюшной полости.

Целью исследования является повышение эффективности врачебной деятельности с помощью СППВР, основанной на знаниях, при использовании теории нечетких множеств и нейросетевых технологий.

В текущий период, определено, что при хирургическом вмешательстве пациентов с рассматриваемым диагнозом существует ряд проблем [1-5]:

- отсутствие ярко-выраженных критериев степени тяжести заболевания, позволяющих на первичном этапе исследования решить вопрос о методе операции
- нет согласованной единой тактики лечения больных с грыжами брюшной полости в зависимости от степени их сложности
- нет единого мнения о необходимости применения дополнительных сетчатых материалов при лечении пациентов с данным диагнозом
- не существует общепринятого решения наилучшего размещения синтетического протеза при послеоперационных грыжах.

В настоящий момент в каждом конкретном случае хирург выбирает способ лечения, основываясь на своем личном опыте. Значительный процент рецидива заболевания говорит о ненадежности такого подхода. Для устранения этой проблемы принято решение реализовать экспертную систему рекомендательного характера, которая бы помогла обобщить врачебный опыт положительных результатов лечения.

Данная система разрабатывается совместными усилиями кафедры ВММБ ПНИПУ под руководством профессора В.Ю. Столбова и кафедры общей хирургии №1 ПГМУ им. академика Е.А.Вагнера под руководством профессора В.А. Самарцева и доцента В.А. Гаврилова, а результаты исследования могут быть применены в медицинских учреждениях Пермского края.

Постановка задачи и общий алгоритм решения. На основе анализа литературных источников по использованию теории нечетких множеств и нейросетевых технологий при разработке медицинских систем для различных заболеваний [6-10] поставлена следующая математическая задача прогнозирования. Считается, что существует следующая зависимость

$$Y = F(X), \quad (1)$$

где X – исходные данные о пациенте; Y – результаты лечения; F – оператор, определяющий технологию лечения в зависимости от данных о пациенте. При этом оператор F в общем случае неизвестен. Однако известны результаты лечения для некоторой группы пациентов.

Предлагается приближенное определение оператора F с помощью обработки исходных данных методами искусственного интеллекта.

Для этого предлагается следующий общий алгоритм решения, включающий последовательное решение задач кластеризации, классификации и прогнозирования.

1. Кластеризация данных

Множество данных X разбивается на подмножества (классы) S_1, S_2, \dots, S_k , где k заранее неизвестно и определяется из решения задачи кластеризации. После определения классов соотношение (1) можно переписать в виде:

$$Y = F(X) = F(S_1, S_2, \dots, S_k). \quad (2)$$

2. Декомпозиция задачи

Считается, что для каждого класса пациентов существует такая технология лечения, при которой будут достигаться близкие результаты. Тогда

$$y_i = F_i(s_i), i=1, k \quad (3)$$

Таким образом задача (1) разбивается на k более простых задач классификации и прогнозирования (3). Другими словами, на основе персональных данных пациент относится к одному из классов, для которого определены наиболее эффективные методы лечения. Операторы F_i в общем виде неизвестны, но их можно приближенно найти с помощью экспертной системы, основанной на знаниях хирургов, а также на основе теории нечетких множеств и нейросетевых технологий.

Модель прогнозирования. На данном этапе построена и обучена прогнозирующая модель на основе теории нечетких множеств и нейросетевых технологий для решения следующих частных задач:

- Задача определения технологии лечения для пациента i -го класса.
- Задача прогнозирования неблагоприятных событий.

Для решения задач определен язык программирования Python и библиотеки sklearn, pandas, numpy, matplotlib. В качестве платформы для вычислений выбран Google Colab.

От экспертов в области медицины был получен источник данных – ретроспективная база данных на 932 пациента за 3 года. Пациенты в этой базе данных деперсонализированы и имеют только определенный номер. Таблица имеет 932 значения (объектов) и 129 столбцов (характеристик пациентов). В качестве набора данных для кластеризации берутся только те признаки, критерий важности которых, согласно мнению экспертов, является высоким. Выбранные параметры переработаны в нечеткую порядковую шкалу в интервале чисел от 0 до 1, которые указывают на степень тяжести того или иного признака. Чем степень тяжести легче, тем показатель ближе к нулю, чем степень тяжести сильнее, тем показатель ближе к единице, если отсутствует признак, то 0.

По результатам проведения кластеризации методами иерархии и k -средних [11, 12] выделено 4 класса пациентов. Численности каждого класса изображены на рис. 1.




Рисунок 1. Диаграмма распределения пациентов по классам

В первом классе большинство операций – 69% сделаны с применением техники использования местных тканей, 19% занимает метод Sublay и небольшой процент составляет использование методов Inlay и Onlay (см.рис.2).




Рисунок 2. Диаграмма распределения методов операционного вмешательства в первом классе

Во второй класс попали пациенты, для которых самым применяемым методом операционного вмешательства стал Sublay – 46%, операция с применением местных тканей выполняется почти в каждом третьем случае – 30%, а для 14% пациентов был использован метод Onlay. Отметим, что только во второй класс попали пациенты, для которых был выбран метод TAR (см. рис.3).




Рисунок 3. Диаграмма распределения методов операционного вмешательства во втором классе

В третьем классе 2/3 операций проводились с использованием метода Лихтенштейн, в 27% использовались местные ткани, а TAPP использовался в 5% случаев, что показано на рис.4.




Рисунок 4. Диаграмма распределения методов операционного вмешательства в третьем классе

Для пациентов, выделенных в четвертый класс, в большинстве операций – 70% использован метод Лихтенштейн, 25% с использованием местных тканей, а остальные – TAPP (см. рис.5).




Рисунок 5. Диаграмма распределения методов операционного вмешательства в четвертом классе

Отметим, что второй класс выделяется тем, что только в нем присутствуют летальные исходы, распределение которых показано на рис.6.




Рисунок 6. Распределение летальных исходов по классам

На этапе прогнозирования реализуется нечеткий алгоритм k-ближайших соседей. Для нахождения расстояния между объектами используется метрика Евклида. Метод операции выбирается на основе схожести по характеристикам исследуемого объекта с объектами, используемыми при обучении модели. Число соседей, с которыми сравнивается исследуемый объект, варьируется от 1 до 40.

По завершению этапа прогнозирования метода операционного вмешательства для каждого класса получены зависимости значения процента несоответствия от количества k-соседей при сравнении результатов, полученных при использовании нечеткого алгоритма k-ближайших соседей, с исходными данными о методах лечения. По горизонтальной шкале отображается число k-соседей, на которое опирается метод при вычислении. По вертикальной шкале расположены значения процента несоответствия.

Для первого класса процент несоответствия варьируется от 0,17 до 0,27 (см. рис.7).




Рисунок 7. Диаграмма значения процента ошибки при сравнении полученных методов операционного вмешательства с исходными для первого класса

Для остальных классов получены аналогичные графики. Для пациентов второго класса значение процента несоответствия в среднем составляет 0,25. Для третьего класса значение процента несоответствия находится в пределах от 0,22 до 0,25. Для четвертого класса средний показатель составляет 0,20.

При использовании нечеткого метода k-ближайших соседей соответствие прогнозирования метода лечения с примененным методом на практике равен 76%, что соответствует результатам схожих СППВР при диагностике других заболеваний. При этом, согласно мнению практикующих хирургов, для оставшихся 24% возможен выбор другого метода лечения.

Для сравнения и повышения уверенности достоверности полученных результатов разработана искусственная нейронная сеть в виде персептрона, которая имеет следующие параметры:

- входной слой, содержащий 47 нейронов;
- один скрытый слой, содержащий 120 нейронов;
- выходной слой, содержащий 9 нейронов.

Количество нейронов на входном слое совпадает с количеством входных параметров пациента.

Оптимальное количество нейронов скрытого слоя, как и само количество скрытых слоёв, было также подобрано экспериментальным путём.

Количество нейронов на выходном слое совпадает с количеством методов операционного вмешательства, используемых в клинической практике.

В ходе обучения на вход нейронной сети подавался вектор параметров пациента, а в качестве желаемого результата – метод лечения, который применялся к данному пациенту в реальности.

Выборка данных была разделена на три: обучающую, валидационную и тестовую.

На рис. 8 показан график изменения величины ошибки сети в зависимости от эпохи обучения.




Рисунок 8. График изменения ошибки при обучении сети

Наименьшее значение ошибки на обучающей выборке было достигнуто на 864 эпохе. Минимальное значение ошибки на тестовой выборке, было достигнуто на 96-ой эпохе обучения, после чего начал проявляться эффект переобучения. В итоговой конфигурации сети использовались весовые коэффициенты, полученные на 96-ой эпохе обучения.

Обученная нейронная сеть была протестирована на тестовой выборке данных, для которых также заранее был известен используемый метод операции.

На тестовой выборке сеть показала по критерию Топ-1 точность в 74%. Но, стоит отметить, что по критерию Топ-2 точность при этом составила 96%. Это означает, что в 96 случаев из 100 правильный вариант метода находился на первом, либо втором месте по эффективности. Данный результат является более чем удовлетворительным, учитывая тот факт, что выбор производится из девяти возможных методов.

Заключение. По результатам исследования реализована математическая модель прогнозирования методов лечения грыж брюшной полости. Решены задачи кластеризации, классификации и прогнозирования методов лечения. Все полученные результаты проанализированы при поддержке экспертов в области медицины. По итогам кластеризации было выбрано 4 класса пациентов. Соответствие прогнозирования метода лечения с проведенным методом равен 74-76%, что соответствует результатам схожих СППВР при диагностике других заболеваний. При этом, согласно мнению практикующих хирургов, для оставшихся 24-26% возможен выбор другого метода лечения.

Работа выполнена при поддержке гранта Пермского края на развитие научной школы по компьютерной биомеханике и цифровой медицины.

Библиографический список

1. Паршаков А.А., Гаврилов В.А., Самарцев В.А. Профилактика осложнений в хирургии послеоперационных грыж передней брюшной стенки: современное состояние проблемы (обзор) // Современные технологии в медицине. 2018. Т. 10. № 2. С. 175-186.
2. Противоспаечные барьеры в абдоминальной хирургии: современное состояние проблемы / В.А. Самарцев, М.В. Кузнецова, В.А. Гаврилов, М.В. Кузнецова, А.А. Паршаков // Пермский медицинский журнал. 2017. Т. 34 (2). С. 87–93.
3. Самарцев В.А., Гаврилов В.А., Осокин А.С., Сидоренко А.Ю., Кузнецова М.П. Профилактика тромбоэмболических осложнений в многопрофильной хирургической клинике у больных с перитонитом // В сборнике: ПЕРИТОНИТ ОТ А ДО Я. Материалы IX Всероссийской конференции общих хирургов с международным участием. Под редакцией А.Б. Ларичева. 2016. С. 396-397.
4. Самарцев В.А., Вильдеман В.Э., Словиков С.В., Гаврилов В.А., Паршаков А.А., Кузнецова М.П., Сидоренко А.Ю. Оценка биомеханических свойств современных хирургических сетчатых имплантатов: экспериментальное исследование // Российский журнал биомеханики. 2017. Т. 21. № 4. С. 441-447.
5. Задняя сепарационная герниопластика TAR при послеоперационных вентральных грыжах W3 / В.А. Самарцев, В.А. Гаврилов, А.А. Паршаков, М.В. Кузнецова // Пермский медицинский журнал. 2017. Т. 34 (1). С. 35–42.
6. Оразбаев Б.Б. Экспертные системы для медицинской диагностики с применением методов теории нечетких множеств // ИТпортал. 2016. №4 (12).
7. Пархоменко С. А., Субботина Т. И., Бойцова Е. А., Хрипина И. И., Цымбал Е. В. Оценка степени тяжести гангрены нижних конечностей на основе нечетких математических моделей // ВНМТ. 2018. №4.

8. Абдухалимова З. К., Белов С. В. Разработка системы диагностики состояния костных тканей в стоматологии посредством анализа рентген-снимков // European science. 2018. №4 (36).
9. Стрункин Д. Ю., Абдрахманов Э. Ф. Система прогнозирования индивидуальной выживаемости пациентов на основе нечеткой нейронной сети // Врач и информационные технологии. 2012. №5.
10. Коробова Л.А., Гладких Т.В. Разработка модели принятия решения для постановки диагноза заболеваний на основе нечеткой логики // Вестник ВГУИТ. 2018. №4 (78).
11. Жамбю М. Иерархический кластер-анализ и соответствия. – М.: Финансы и статистика, 1988. – 345 с.
12. Тюрин А.Г., Зуев И.О. Кластерный анализ, методы и алгоритмы кластеризации // Вестник МГТУ МИРЭА. №12. М.: Изд-во МГТУ, 2014.

DEVELOPMENT OF A CLINICAL DECISION SUPPORT SYSTEM BASED ON ARTIFICIAL INTELLIGENCE METHODS

Perehygin Lev Y., Stolbov Valeriy Y., Mulyukin Sergey V.

Perm National Research Polytechnic University

Str. Professora Pozdeeva, 13, Perm, Russia, 614000, leoperelygin@gmail.com

Gavrilov Vasily A.

Perm State Medical University

Str. Kuybysheva, 39, Perm, Russia, 614000, inmyplay@mail.ru

The article describes the development of a medical decision support system when choosing a treatment method for patients with abdominal hernias. The system allows to classify a patient into one of certain groups and predict the patient's treatment method, taking into account his characteristics. The system can make predictions in two ways – based on the k-nearest neighbors method and based on neural network technologies. Using real data, the clustering problem is solved and four classes of patients are identified. The prediction accuracy of the required treatment method is 74-76%. According to medical experts, an alternative method of surgery is possible for the rest of the patients. The obtained results are adequate and can be applied in practical medicine.

Key words: artificial intelligence, k-nearest neighbors algorithm, neural network technologies, abdominal surgery, clustering, classification, prediction, abdominal hernia.

**ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ
В ПРОГНОЗИРОВАНИИ КОЛИЧЕСТВА ПОСТУПИВШИХ
ОБРАЩЕНИЙ В СЛУЖБУ ТЕХНИЧЕСКОЙ ПОДДЕРЖКИ
РЕГИОНАЛЬНОЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ В СФЕРЕ
ЗАКУПОК ТОВАРОВ, РАБОТ, УСЛУГ ДЛЯ ОБЕСПЕЧЕНИЯ
ГОСУДАРСТВЕННЫХ НУЖД ПЕРМСКОГО КРАЯ**

Зарипова Анна Фаритовна

Государственное Бюджетное Учреждение «Центр Организации Закупок»
614990, Россия, г. Пермь, ул. Петропавловская, 53, afzaripova@cz.permkrai.ru

Построена нейронная сеть, позволяющая прогнозировать количество обращений в службу технической поддержки.

Ключевые слова: РИС ЗАКУПКИ ПК, техническая поддержка, нейронная сеть.

Система РИС ЗАКУПКИ ПК начала функционировать в 2017 году на основании Постановления Правительства Пермского края от 24 августа 2017 г. №731-п "О региональной информационной системе в сфере закупок товаров, работ, услуг для обеспечения государственных нужд Пермского края".

Система включает в себя совокупность содержащейся в базах данных информации и обеспечивающих ее обработку информационных технологий и технических средств, соответствующих законодательству, определяющему требования к информационным системам в сфере закупок товаров, работ, услуг для обеспечения государственных и муниципальных нужд.

Система взаимодействует со следующими информационными системами:

- ЕИС,
- ЕИС УФХД,
- облачная бухгалтерия,
- АЦК-Финансы,
- АЦК-Планирование,
- Портал Поставщиков.

Информационное и технологическое взаимодействие между системами осуществляется путем их интеграции посредством программной и технологической инфраструктуры, обеспечивающей обмен информацией между системами. Порядок интеграции определяется регламентами информационного взаимодействия, которые при необходимости разрабатываются и согласуются совместно с операторами соответствующих информационных систем.

Поскольку система РИС ЗАКУПКИ ПК – относительно молодая, а в законодательстве в области осуществления государственных закупок регулярно происходят изменения, то довольно часто у пользователей возникают вопросы технического характера.

Для подобных случаев существует служба технической поддержки, куда любой пользователь может обратиться по телефону или электронной почте:

8-800-555-44-50, support-goszakaz@permkrai.ru

1. Актуальность. Согласно РЕГЛАМЕНТА ОБРАБОТКИ ОБРАЩЕНИЙ ПОЛЬЗОВАТЕЛЕЙ РЕГИОНАЛЬНОЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ В СФЕРЕ ЗАКУПОК ТОВАРОВ, РАБОТ, УСЛУГ ДЛЯ ОБЕСПЕЧЕНИЯ НУЖД ПЕРМСКОГО КРАЯ в процессе обработки обращений пользователей участвуют три линии поддержки:

1. **первая линия поддержки:** прием и регистрация обращений, первичная информационно-справочная поддержка пользователей по типовым вопросам;

2. **вторая линия поддержки:** информационно-справочная поддержка пользователей по вопросам, выходящим за пределы компетенции первой линии поддержки и требующим высокий уровень компетенции;

3. **третья линия поддержки:** техническая поддержка пользователей (устранение ошибок, проведение изменений, доработок программного обеспечения и т.п.).

Одной из задач отдела сопровождения закупок Государственного Бюджетного Учреждения «Центр Организации Закупок» является **прогнозирование количества поступивших обращений.**

Правильный прогноз поможет дать ответ на несколько текущих вопросов:

1. необходимость изменения штатного расписания (расчет численности операторов технической поддержки);

2. корректирование режима работы технической поддержки;

3. изменение SLA (соглашения о допустимом времени для предоставления решения по обращению);

4. прогнозирование массовых инцидентов и пиковых нагрузок для проведения подготовительных мероприятий.

2. Построение нейросетевой модели.

В случае с обращениями в службу технической поддержки РИС ЗАКУПКИ ПК собрать все значимые входные параметры в одну связанную таблицу в короткое время оказалось невозможно по различным причинам, в основном – не достоверные или разрозненные сведения.

Однако для первой попытки проектирования сети были собраны наиболее достоверные данные.

В качестве входных параметров нейросетевой математической модели использовались следующие факторы:

x_1 – Год подачи обращения 2018: 0 – нет; 1 – да.

x_2 – Год подачи обращения 2019: 0 – нет; 1 – да.

$x_3 - x_{14}$ – Месяца с января по декабрь: 0 – нет; 1 – да.

x_{15} – Порядковый номер недели месяца: значения от 1 до 5.

x_{16} – Наличие обновлений в Системе: 0 – нет; 1 – да.

x_{17} – Наличие массовых технических ошибок различного характера в Системе: 0 – нет; 1 – да.

Выходной параметр модели d – результат прогноза: количество заявок, полученных за указанный период времени.

Анализ сведений, полученных из Системы Управления Инцидентами, в которой происходит регистрация и обработка обращений, а также мониторинг новостей Системы на наличие уведомлений об обновлениях и массовых ошибках, позволили сформировать выборку из 68 строк за каждую неделю с августа 2018 года по октябрь 2019 года.

Далее все множество было разбито в соотношении, ориентировочно 90% : 10% на обучающее, использованное для обучения сети, и тестирующее, предназначенное для проверки ее прогностических свойств. Примеры тестирующего множества при обучении сети не использовались.

Среднеквадратичная ошибка тестирования (обобщения) составила 15%. Таким образом, можно утверждать, что нейронная сеть, хотя и с погрешностью, но научилась высчитывать зависимость между входными параметрами и количеством обращений.

3. Исследование модели. После того, как работа нейросети была проверена на тестовых примерах и, таким образом, проверена адекватность нейросетевой математической модели, можно приступить к ее исследованию. Прежде всего, путем поочередного исключения входных нейронов и наблюдением за погрешностью сети была определена значимость входных параметров модели, т.е. – степень их влияния на результат моделирования. Как видно из рисунка 1, наиболее значимыми входными параметрами оказались два месяца: Январь и Май, в которые вступили в силу серьезные изменения в законодательстве, а также год подачи заявки. Наименее значимым параметром оказался порядковый номер недели в месяце.




Рисунок 1. Наиболее значимые параметры, влияющие на количество обращений в службу технической поддержки

По результатам обучения был составлен прогноз количества заявок на оставшиеся недели в 2019 году, в зависимости от наличия и отсутствия массовых ошибок и/или обновлений системы. Как видно на рисунках 2,3,4,5 количество заявок будет расти при наличии обновлений системы и массовых ошибок все сильнее ближе к концу года.




Рисунок 2. Зависимость количества заявок от недели без обновлений и массовых ошибок




Рисунок 3. Зависимость количества заявок от недели при наличии массовых ошибок




Рисунок 4. Зависимость количества заявок от недели при наличии обновлений системы




Рисунок 5. Зависимость количества заявок от недели при наличии обновлений системы и массовых ошибок

Обсуждение результатов и заключение. По результатам данного моделирования были выявлены недостатки выборки. В дальнейшем будут добавлены новые параметры и примеры не по неделям, а на каждый день.

Необходимо более внимательно подбирать тестовое множество для лучших результатов, что требует предварительного анализа.

Будут учтены следующие факторы:

- обновления системы и массовые ошибки по балльной шкале
- количество аттестованных и неаттестованных пользователей системы, т.е. не завершивших обучение по работе в РИС ЗАКУПКИ ПК
- количество Заказчиков (организаций), зарегистрированных в системе
- оценка изменения действующего законодательства при наличии по субъективной балльной шкале
- проведение вебинаров и семинаров на актуальные темы.

Также следует более тщательно подойти к проектированию сети и выбору подходящих активационных функций, т.к. изменится количество входных параметров.

Сам проект по прогнозированию количества поступивших обращений считаю жизнеспособным, однако, он требует определенной доработки.

Библиографический список

1. Интеллектуальные системы: учебник / Л.Н. Ясницкий. – М.: Лаборатория знаний, 2016. 221с.
2. Статистические методы интеллектуального анализа данных: учеб. Пособие / Л.А. Мыльников. – Пермь. Изд-во Перм.нац.исслед.политехн.ун-та, 2018 – 164с.

3. Глубокое обучение / Николенко С., Кадурич А., Архангельская Е. – СПб.: Питер, 2018. – 480 с.

APPLICATION OF NEURAL NETWORK TECHNOLOGIES FOR FORECASTING THE NUMBER OF APPEALS RECEIVED TO THE SERVICE OF TECHNICAL SUPPORT OF THE REGIONAL INFORMATION SYSTEM IN THE FIELD OF PURCHASE OF GOODS, WORKS, SERVICES FOR SECURING STATE NEEDS OF THE PERM REGION

Zaripova Anna Faritovna.

State Budget Institution "Center for the Organization of Purchasing."
614990, Russia, Perm, ul. Petropavlovskaya, 53, afzaripova@cz.permkrai.ru

A neural network has been built to predict the number of calls to technical support.
Key words: RIS ZAKUPKI PK, technical support, neural network.

УДК 004.89

СРАВНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ОЦЕНКИ СТУДЕНТА ЗА УЧЕБНУЮ ДИСЦИПЛИНУ НА ОСНОВЕ ЕГО ПРЕДЫДУЩИХ ОЦЕНОК

Коротков Иван Сергеевич

Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15, iskorotkov@psu.ru

В статье описано создание трех моделей машинного обучения: нейронной сети и моделей ML.NET. Построенные модели позволяют предсказать оценку студента за дисциплину на основе его предыдущих оценок. Было проведено сравнение трех моделей как в точности предсказаний, так и в скорости создания и обучения, после чего были сделаны выводы о том, в каких случаях для решения поставленной задачи имеет смысл использовать нейронные сети, а в каких достаточно альтернативных методов машинного обучения.

Ключевые слова: студенты, оценка, нейронные сети, прогнозирование, машинное обучение, регрессия, .Net, ML.NET.

Введение. В статье описано сравнение моделей для прогнозирования оценки за учебную дисциплину. В основе первой модели лежит нейронная сеть, в основе второй и третьей – обученные модели на основе ML.NET. Полученные модели с приемлемой точностью позволяют предсказать оценку

по 100-бальной шкале студента за конкретную дисциплину, основываясь на данных об его успеваемости в прошлом и информации о дисциплине.

Практическая ценность заключается в двух аспектах. Во-первых, предсказание оценки позволит студенту сосредоточить больше сил на дисциплинах, по которым ожидаются большие затруднения, и тратить меньше времени на дисциплины, по которым прогнозируются высокие оценки. Во-вторых, данная работа позволяет сравнить два разных метода прогнозирования: более сложный вариант, требующий как минимум начальных знаний в машинном обучении – создание и использование нейронной сети с помощью программы «Нейросимулятор 5», и более простой – использование фреймворка ML.NET для создания модели машинного обучения [1].

Целью работы является сравнение двух методов МО для прогнозирования оценки студента. Результатом работы является вывод о том, в каких случаях имеет смысл применять нейронные сети, а в каких больше подходят альтернативные методы машинного обучения.

Подобные работы. Попытки предсказать оценку студента в ЕТИС предпринимались в работе [2]. Также регрессионные модели для предсказания оценок студентов создаются в работе [3].

Определение входных параметров. В таблице 1 представлена информация о входных параметрах для моделей.

Таблица 1 – Входные параметры

Столбец	Название	Особенности
X1-X2	Курс	Категория, применяется one-hot encoding
X3-X7	Триместр	Категория, применяется one-hot encoding
X8-X13	Категория предмета	Категория, применяется one-hot encoding
X14-37	Предмет	Категория, применяется one-hot encoding, прикладная физическая культура не учитывается
X38	Экзамен или зачет	
X39	Часов аудиторной работы	Учитываются только аудиторные часы
X40	Количество контрольных точек	Входной контроль не учитывается
X41	Является ли предмет профильным	Профильными предметами считаются те, что непосредственно относятся к направлению студента (в случае для направления «прикладная математика и информатика» – все дисциплины, связанные с

Столбец	Название	Особенности
		математикой и программированием)
X42	Количество пропусков	
X43	Размер стипендии на начало триместра	
X44	Наличие у студента интереса к предмету	
X45-X53	Минимальная оценка; максимальная оценка; средняя оценка; медианная оценка; дисперсия оценок; 10-й перцентиль оценок; нижний квантиль оценок; верхний квантиль оценок; 90-й перцентиль оценок	Статистические параметры считаются по следующим значениям в порядке приоритета: 1. по оценкам студента за предыдущие триместры для дисциплин той же категории, что и данная дисциплина; 2. по всем оценкам студента за предыдущие триместры для дисциплин. 3. берется значение по умолчанию 80. Стоит заметить, что этот вариант используется только в том случае, если у студента нет ни одной оценки.
D1	Оценка	Предсказываемое значение

Сбор данных. Для сбора данных создан документ Excel, в который опрашиваемые студенты заносили свои данные. Были собраны данные 6 бакалавров-второкурсников направления «Прикладная математика и информатика» механико-математического факультета Пермского государственного национального исследовательского университета (ПГНИУ). Всего в датасете 180 записей, по 30 с каждого опрошенного студента (по числу сданных ими дисциплин).

Предобработка датасета. Перед использованием в обучении датасет подвергается следующим операциям:

1. Преобразование из .xlsx в .csv.
2. Добавление статистических параметров X45-X53.
3. Перемешивание датасета.
4. Разделение датасета на три множества (обучающее – 70%, проверяющее – 15% и тестовое – 15%).
5. Добавление аугментаций к обучающему множеству. Для каждого примера из обучающего множества размер стипендии, статистические значения и полученная оценка (т. е. предсказываемое значение) умножаются на случайное значение от 0.95 до 1.05 и полученный пример добавляется в обучающее множество. При количестве аугментаций на каждый исходный пример, равном 50, количество примеров в обучающем множестве увеличивается в 51 раз.

6. Перемешивание примеров внутри каждого множества.
7. Применение one-hot encoding для категориальных параметров.
8. Создание .xlsx файла с тремя листами с соответствующими множествами.

Таким образом, в результате получается три множества: обучающее, состоящее из 6426 записей, а также проверочное и тестовое, состоящие из 27 записей. Каждая запись содержит 54 атрибута: 53 входных параметра и 1 ожидаемое выходное значение.

Создание и обучение моделей.

Для обучения нейронной сети использовался «Нейросимулятор 5». Гиперпараметры модели представлены в таблице 2.

Таблица 2 – Гиперпараметры нейронной сети

Параметр	Значение
Структура нейронной сети	Полносвязный слой (53, сигмоида) Полносвязный слой (8, сигмоида) Полносвязный слой (1, сигмоида)
Алгоритм обучения	Алгоритм Левенберга-Марквардта
Инициализация весов	Автоматически
Функциональная предобработка	Голосование
Линейное масштабирование	A: -1, B: 1
Количество итераций	25

Для создания модели ML.NET использовалась среда разработки Visual Studio 2019 Preview и расширение для нее ML.NET Model Builder (Preview). Данное расширение позволяет автоматически сгенерировать код для создания, обучения и использования модели машинного обучения, а также автоматически выбирает наиболее точный алгоритм машинного обучения для решения поставленной задачи. В нашем случае расширение сгенерировало код для алгоритма машинного обучения LightGBM, т. к. он, по предварительной оценке, показывал наибольшую точность. После завершения работы с расширением получается обученная и готовая модель машинного обучения.

После обучения модели ML.NET, автоматически сгенерированной расширением, есть возможность улучшить ее эффективность, изменив алгоритм или подобрав более подходящие параметры. В результате в качестве алгоритма опытным путем был выбран GAM (generalized additive models) со скоростью обучения 0.035.

Сравнение использованных методов машинного обучения. Полученные модели машинного обучения можно оценить по результатам их работы на тестовом множестве (таблица 3).

Таблица 3 – Сравнение нейронной сети и модели ML.NET

Величина	Нейронная сеть	Модель ML.NET	Оптимизированная модель ML.NET
Среднеквадратичное отклонение	12.7631%	13.6523%	12.3232%
Средняя относительная ошибка	12.565%	16.2201%	14.4713%
Средняя абсолютная ошибка	8.7955 баллов	10.0294 баллов	9.1357 баллов
Медиана абсолютных ошибок	6.7788 баллов	8.6689 баллов	6.8575 баллов
Максимальные значения ошибки	49.77 баллов 20.28 баллов 13.68 баллов	48.46 баллов 19.74 баллов 18.13 баллов	34.49 баллов 25.73 баллов 23.77 баллов
Количество примеров с ошибкой от 0 до 5	10 из 27 (37%)	9 из 27 (33.3%)	10 из 27 (37%)
Количество примеров с ошибкой от 5 до 10	9 из 27 (33.3%)	8 из 27 (29.6%)	10 из 27 (37%)
Количество примеров с ошибкой от 10 до 20	6 из 27 (22.2%)	9 из 27 (33.4%)	3 из 27 (11.1%)
Количество примеров с ошибкой больше 20	2 из 27 (7.4%)	1 из 27 (3.7%)	4 из 27 (14.8%)

По метрикам всех трех моделей становится очевидно, что они справляются с предсказанием оценок студентов, но нейронная сеть справляется с этим незначительно лучше.

На подбор гиперпараметров для нейронной сети ушла большая часть времени и вычислительных ресурсов, затраченных на выполнение данной работы. Напротив, создание модели ML.NET отнимает очень мало времени благодаря автоматическому подбору метода и генерации кода. Это является преимуществом в тех случаях, когда решаемые задачи достаточно просты и требуется сэкономить ресурсы на использовании более продвинутых решений.

На рисунках 1-2 приводится сравнение всех трех моделей на тестовом множестве.




Рисунок 1. Сравнение реальных и предсказанных моделями значений для примеров тестового множества




Рисунок 2. Ошибка моделей на примерах тестового множества

Выводы. В результате обучения трех моделей машинного обучения получены следующие выводы:

1. Создание и обучение нейронной сети требует намного больше знаний, времени и вычислительных мощностей, поэтому в некоторых случаях (при отсутствии соответствующих знаний, времени или при создании прототипа) эффективнее использовать другие методы – например, модели ML.NET.

2. Нейронная сеть имеет бóльшую точность предсказаний, поэтому в тех случаях, когда время создания и обучения не имеет значения, а точность предсказаний имеет большое значение, имеет смысл использовать нейронные сети.

Библиографический список

1. ML.NET | Microsoft Docs – <https://docs.microsoft.com/en-us/dotnet/machine-learning/automate-training-with-model-builder>
2. Кузнецов А. Г., Федорук М. Н., Митрофанов И. А. Разработка интеллектуальной системы диагностики и прогнозирования оценки за экзамен // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всероссийской научно-практической конференции (г. Пермь, 21-23 мая 2019) Часть I. / Пермский государственный национальный исследовательский университет – Пермь, 2019.
3. Моисеев В. Б., Зубков А. Ф., Деркаченко В. Н. Прогнозирование успеваемости студентов по общепрофессиональным и специальным дисциплинам на основе регрессионных моделей // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика, телекоммуникации и управление. 2010 г. № 6 (113).

COMPARISON OF MACHINE LEARNING METHODS TO PREDICT STUDENT'S SCORES FOR A SUBJECT BASED ON HIS PREVIOUS MARKS

Korotkov Ivan S.

Perm State University

614990, Russia, Perm, street Bukireva, 15, iskorotkov@psu.ru

This article describes the creation of three machine learning models: a neural network and two ML.NET models. Created models are designed to predict student's scores for a subject based on his previous scores. The comparison of the models in prediction accuracy and speed of creation and learning was conducted that allowed to make conclusions about possible use cases for neural networks and alternative machine learning models in students' scores prediction.

Key words: students, scores, neural networks, prediction, machine learning, regression, .Net, ML.NET.

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПРОДАЖ ВИДЕОИГР В ПЕРВУЮ НЕДЕЛЮ ПОСЛЕ ВЫПУСКА

Ковалев Алексей Владимирович

Пермский Государственный национальный Исследовательский Университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, Alekov99@mail.ru

Представлено описание разработки нейросетевой системы для прогнозирования продаж видеоигр в первую неделю после выхода. Система позволяет спрогнозировать продажи видеоигры по десяти входным параметрам, таким как: бюджет, год выпуска, жанр, платформа и т.д. Также система обладает возможностью выявления тенденции изменения количества продаж в зависимости от входных параметров.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, оценка продаж, видеоигры, компьютерные игры.

Введение. В настоящее время видеоигры вносят значительный вклад в мировую экономику ввиду большого успеха продаж основных игровых систем и игр. Так игра Grand Theft Auto 5 за первые 3 дня продаж удалось заработать 1 млрд. долларов.

На начальном этапе существования компьютерных игр стоимость разработки была минимальной, поэтому это был прибыльный бизнес. Игры разрабатывались единственным программистом или небольшой группой в течении нескольких месяцев, иногда года.

В настоящее время стоимость разработки может достигать десятков миллионов долларов. По мере развития компьютерных технологий, увеличивался и размер групп разработчиков, так как увеличивающаяся сложность графики и программирования в целом требовала все большего штата специалистов. Большинство профессионально выполненных видеоигр разрабатываются в течение нескольких лет.

Прогнозирование продаж игр в первую неделю, исходя из хода разработки – это очень актуальная тема, выходит множество видеоигр, и по первой неделе продаж, возможно определить, окупится игра или нет. Данная нейросеть может помочь разработчикам понять, какую игру лучше разрабатывать, чтобы она стала успешной и тем самым прибыльной.

При поиске подобных работ была найдена аналогичная работа по прогнозированию продаж видеоигр в первую неделю после выпуска [15], но в ней использовалось меньшее множество примеров (всего 66), и другая структура нейронной сети.

Для проектирования сети необходимо определить входные параметры, с помощью которых будут прогнозировать продажи. По собственному опыту

и доступной информации в интернете были выбраны следующие параметры: X1 – Платформа (1-ПК, 2-консоль, 3-кроссплатформенный), X2 – Год выхода, X3 – Жанр (1-Действие, 2-Симулятор, 3-Приключения, 4-Стратегия, 5- Головоломка, 6-Ролевая, 7-Смешанная), X4 – Режим игры (1-однопользовательский, 2-многопользовательский, 3-однопользовательский и многопользовательский), X5 – Бюджет (в долларах), X6 – Является продолжением серии, X7 – Оценка на MetaCritic от критиков, X8 – Оценка на MetaCritic от пользователей, X9 – Является инди-игрой, X10 – Наличие открытого мира. Выходной параметр D1 – Количество проданных копий за первую неделю. Жанр игр были выбраны основываясь на информации со страницы википедии [11]. Функциями активации выступает тангенс гиперболический. **Рисунок 12** представляет структуру нейронной сети.




Рисунок 12. Структура нейронной сети

Для обучения сети было сформировано множество примеров, взятое из интернета, размер которого составил 80 штук. С сайта Википедия [1] была взята информация о Платформе, Годе выхода, Жанре, Режиме игры, Является ли игра продолжением серии, Наличие открытого мира. Оценки пользователей и критиков были взяты с официального сайта MetaCritic [4]. Некоторые бюджеты и количество проданных копий за первую неделю брались с множества сайтов, таких как: Игропоиск [3], 3dnews [5], Gametech [6], Playground [7], Pikabu [8], Игромания [9] и также с википедии [1]. Бюджет самых дорогих игр был взят со страницы википедии [2], также некоторые бюджеты были взяты с сайта [10]. Множество примеров имеет такой маленький размер, так как не все издатели раскрывают бюджеты, потраченный на разработку.

Проектирование нейронной сети проводилось в программе «Нейросимулятор 5» [Ошибка! Источник ссылки не найден.]. Обучающее множество состояло из 72, тестирующее из 8 (10% от обучающего). При обучении использовался алгоритм упругого распространения, описанный в книге [12].

Средняя кв. ошибка на тестирующем множестве составила 18,4%, а на обучающем 1,6%, что является неплохим результатом, при небольшом наборе примеров.

Рисунок 13 [Ошибка! Источник ссылки не найден.] представляет результаты тестирования, полученной нейронной сети на тестирующем множестве.




Рисунок 13. Результаты тестирования

После того как работа нейронной сети проверена на тестовых примерах и, таким образом, подтверждена адекватность нейросетевой математической модели, можно приступать к ее исследованию. Обученная нейросетевая модель реагирует на изменение входных переменных и ведет себя так же, как вела бы себя сама предметная область. Поэтому с помощью нейросетевой модели можно проводить исследование предметной области – изучать зависимость прогнозируемой величины от входных параметров.

Рисунок 14 представляет значимость входных параметров.




Рисунок 14. Значимость входных параметров

Таким образом, мы можем видеть, что наибольшее влияние на успешность видеоигры оказывает Бюджет, Оценка критиков и Год выхода.

Рисунок 15 иллюстрирует, то как влияет бюджет игры на количество проданных копий. В ходе этого эксперимента изменялся только один входной параметр (бюджет), а остальные параметры «замораживались», данный метод описан в книге [12].




Рисунок 15. Зависимость продаж от бюджета.

Таким образом, мы можем видеть, что увеличение бюджета увеличит количество проданных копий.

Рисунок 16 иллюстрирует, то как год выхода влияет на количество проданных копий игры. Были взяты 3 игры с разным бюджетом и взят промежуток от 2006 до 2020 года.




Рисунок 16. Зависимость продаж от года выхода.

Таким образом, мы можем видеть, что чем позже вышла игра, тем больше копий будет продано в первую неделю. Также можно увидеть, что у игр с меньшим бюджетом рост продаж идёт быстрее.

Рисунок 17 иллюстрирует то, как оценка критиков влияет на количество проданных копий игры за первую неделю. Были взяты 3 игры с разным бюджетом.




Рисунок 17. Зависимость продаж от оценки критиков

Таким образом, мы можем, видеть, что с увеличением оценки критиков растут продажи.

Закключение. В процессе работы по созданию нейросетевой системы были выявлены характеристики, которые влияют на продажи видеоигр в

первую неделю после выпуска. Эти данные могут использоваться разработчиками и издателями игр на этапе проектирования своей будущей игры для прогнозирования её успешности.

Библиографический список

1. Википедия. Свободная энциклопедия [Электронный ресурс]. – URL: <https://ru.wikipedia.org/wiki/> (дата обращения: 11.06.2020)
2. Википедия. Свободная энциклопедия. Список видеоигр с самым высоким бюджетом разработки [Электронный ресурс]. – URL: https://en.wikipedia.org/wiki/List_of_most_expensive_video_games_to_develop (дата обращения: 11.06.2020)
3. Игропоиск [Электронный ресурс]. – URL: <https://igropoisk.com/> (дата обращения: 11.06.2020)
4. Метакритик [Электронный ресурс]. – URL: <https://www.metacritic.com/> (дата обращения: 11.06.2020)
5. 3dnews [Электронный ресурс]. – URL: <https://3dnews.ru/> (дата обращения: 11.06.2020)
6. Gametech [Электронный ресурс]. – URL: <https://www.gametech.ru/> (дата обращения: 11.06.2020)
7. Playground [Электронный ресурс]. – URL: <https://www.playground.ru/> (дата обращения: 11.06.2020)
8. Pikabu [Электронный ресурс]. – URL: <https://pikabu.ru/> (дата обращения: 11.06.2020)
9. Игромания [Электронный ресурс]. – URL: <https://www.igromania.ru/> (дата обращения: 11.06.2020)
10. Бюджеты современных игр [Электронный ресурс]. – URL: <https://colonelcassad.livejournal.com/1377663.html> (дата обращения: 11.06.2020)
11. Википедия. Свободная энциклопедия. Классификация компьютерных игр [Электронный ресурс]. – URL: https://ru.wikipedia.org/wiki/Классификация_компьютерных_игр (дата обращения: 11.06.2020)
12. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. – 221с.
13. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014
14. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
15. Юрков М.А. Нейросетевое моделирование прогнозирования продаж видеоигр в первую неделю после выпуска // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всерос. науч.-практ. конф. (г. Пермь,

21–24 мая 2019 г.) Ч. I. / Перм. гос. нац. исслед. ун-т. – Пермь, 2019. – 276 с.

NEURAL NETWORK MODELING FORECASTING THE VALUE OF VIDEO GAMES FOR THE FIRST WEEK AFTER THE RELEASE

Kovalev Aleksei Vladimirovich

Perm State University 614990, Russia, Perm, 15 Bukireva str., Alekov99@mail.ru

This article describes the development of a neural network system for forecasting video game sales in the first week after release. The system allows you to predict sales of a video game by ten input parameters, such as budget size, genre, year of production, platform, etc. The system also has the ability to detect trends in the number of sales, depending on the input parameters.

Key words: artificial intelligence, neural network technologies, forecasting, sales evaluation, video games, computer games.

УДК 004.891.3

ПРОГНОЗИРОВАНИЕ ПРОДАЖ ГРУППЫ ТОВАРОВ ИЗ АССОРТИМЕНТА ОРГАНИЗАЦИИ

Лыгалов Илья Сергеевич

Пермский сетевой ИТ-университет 614990, Россия, г. Пермь, ул. Генкеля, 5а (ПГНИУ, корп.3), ауд.310. ligalov@mail.ru

Предметом исследования является компания «TRINITY» и ее рынок сбыта компьютерной техники. Ввиду того прогнозирование продаж является важным фактором при планировании закупок и товарных запасов была поставлена следующая задача: создание компьютерной программы по прогнозированию продаж определенной группы товаров из ассортимента организации. А также выявлению наиболее значимых параметров влияющих на объем продаж. Инструментом исследования являются нейронные сети [1, 2], обучаемые и тестируемые на данных предоставленных организацией.

В качестве единицы времени (t) для прогнозирования и анализа принимается недельный период. Это связано с периодом закупок в организации.

Ключевые слова: продажи, компьютерная техника, искусственный интеллект, прогнозирование, нейронная сеть.

Математическая модель: При постановке задачи в качестве входных параметров нейросетевой математической модели[3] были выбраны критерии, которые напрямую могут влиять на продажи. Для выделения сезонности в продажах вместо временного интервала был использован критерий

сезонности. Так же был применен метод временных рядов для выделения направления тренда.

Всего было использовано 12 входных параметров:

x_1 – сезон;

x_2 – ассортимент;

x_3 – остаток товара на начало периода;

x_4 – средняя цена за единицу товара;

x_5 – продажи за период t-1;

x_6 – продажи за период t-2;

x_7 – продажи за период t-3;

x_8 – продажи за период t-4;

x_9 – продажи за период t-5;

x_{10} – продажи за период t-6;

x_{11} – продажи за период t-7;

x_{12} – продажи за период t-8;

Среди входных параметров модели имеются качественные факторы, характеризующие сезон (x_1). Этот показатель был закодирован следующим образом. Если начало периода t приходится на январь – март, то значению параметра x_1 присваивается «2», если апрель – июнь, то значение «1», июль – сентябрь «3», октябрь – декабрь «4».

Для составления временного ряда были использованы значения восьми предыдущих периодов переменные x_5 – x_{12} .

Выходная переменная принимает Y значение ожидаемого количества проданного товара.

Нейросетевая модель: В качестве источника информации для обучения и тестирования нейронной сети были использованы данные о продажах, остатках и средней стоимости группы товаров в период с 2013 по 2019 годы.

На основании этих данных было сформировано множество, содержащее 308 примеров. Все множество примеров было разделено на обучающее множество, которое составило 268 примеров и тестирующее состоящее из 40 примеров. На обучающем множестве происходило обучение нейронной сети. На тестирующем множестве проверялись прогностические свойства сети.

Проектирование, оптимизация, обучение и тестирование нейронной сети выполнялись с помощью нейропакета «Нейросимулятор» [4]. Оптимальная структура нейронной сети представляла собой персептрон, имеющий двенадцать входных нейронов, один скрытый слой с тремя нейронами и один выходной нейрон. В качестве активационных функций нейронов скрытого слоя и выходного нейрона использовались функции тангенс гиперболический.

После обучения, прогностические свойства сети проверялись на тестирующих примерах.

Для оценки качества нейронной сети использовалась среднеквадратичная относительная погрешность, которая на тестирующем

множестве примеров составила 11,2 %. Поскольку примеры тестирующего множества не использовались при обучении нейронной сети, можно утверждать, что нейронная сеть усвоила закономерности моделируемой предметной области, и теперь ее можно использовать для проведения вычислительных экспериментов.




Рисунок 1 Персептрон




Рисунок 2. Сравнение результатов продаж с прогнозом нейросети

Вторая часть задачи состоит в том, чтобы выяснить значимость входных параметров, т.е. – степень их влияния на результат моделирования – количество проданного товара. Объективную оценку такого влияния можно получить, например, по методике исключения входных параметров с помощью той же нейронной сети путем поочередного исключения входных параметров и наблюдением за погрешностью ее тестирования. Чем выше оказывается погрешность тестирования, тем значимее соответствующий исключенный параметр. Построенная таким способом гистограмма приведена на рисунке 3. Высота столбцов соответствует погрешности тестирования, полученной при исключенном входном параметре, подписанном под столбцом, поэтому ее можно интерпретировать как значимость этого параметра.



Рисунок 3 Значимость параметров продажи товаров

Как видно из гистограммы, самым значимым параметром оказался «Средняя цена за единицу товара». Следующими по значимости идут: «продажи за период t-4», «Сезон» и «Ассортимент».

Обучение, оптимизация и тестирование нейронных сетей проводилось согласно методике, принятой в Пермской научной школе искусственного интеллекта, www.PermAi.ru).

Заключение: Разработана нейросетевая экономико-математическая модель, предназначенная для прогнозирования продаж группы товаров. Модель может быть использована в написании программного продукта для организации «TRINITY». Задачей продукта будет являться поддержка принятия решений на этапе планирования закупки товаров для наиболее эффективного использования финансовых потоков и оптимального поддержания складских остатков.

Библиографический список

1. Л.Н. Ясницкий Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
2. Л.Н. Ясницкий Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
3. Ясницкий Л.Н. Интеллектуальные системы. – М.: Лаборатория знаний, 2016. – 221 с.

4. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

FORECASTING SALES OF A GROUP OF GOODS FROM THE RANGE OF THE ORGANIZATION

Ligalov Ilya S.

Perm State University 614990, Russia, Perm, 5a Genkelya str., ligalov@mail.ru

The subject of the research is the "TRINITY" company and its computer equipment sales market. In view of this, forecasting sales is an important factor in planning purchases and inventory, the following task was set: creating a computer program to forecast sales of a certain group of goods from the assortment of the organization. As well as identifying the most significant parameters affecting sales. The research tool is neural networks [1, 2], trained and tested on the data provided by the organization. The unit of time (t) for forecasting and analysis is a weekly period. This is due to the procurement period in the organization.

Key words: sales, computer hardware, artificial intelligence, forecasting, neural network.

УДК 004.8+616-079

ДИАГНОСТИКА БОЛЕЗНИ СЕРДЦА НА ОСНОВЕ МЕТОДА НЕЙРОННЫХ СЕТЕЙ

Старцев Даниил Сергеевич

Национальный исследовательский университет
«Высшая школа экономики» (Пермский филиал), Россия, г. Пермь, 614046,
ул. Студенческая, 38, *startsevdsk@gmail.com*

На основе симулятора нейронных сетей разработана математическая модель для оценки вероятности наличия болезней сердца у человека без учета поведенческих характеристик. Для доказательства адекватности модели было проведено тестирование. Было выявлено, что наиболее значимым фактором в определении болезни является количество крупных сосудов, выявленных на рентгеноскопии.

Ключевые слова: болезнь, сердце, прогноз, модель, нейронная сеть.

Для диагностики болезней сердца используется множество характеристик, выделяют наиболее распространенные [1]: низкая физическая активность, употребление алкоголя, курение сигарет. Стоит заметить, что здесь присутствуют поведенческие характеристики человека и такие

характеристики записываются со слов пациента, а значит могут быть подвержены искажениям при коммуникации людей. Модели с учетом таких характеристик существуют и развернуты в виде рабочих приложений [2].

В добавление к поведенческим факторам ВОЗ выделяет следующие факторы влияющие на здоровье сердца человека [3]: повышенное артериальное давление, высокий уровень холестерина в крови, индекс массы тела, повышение липидов в крови. Проявление болезней сердца выражено болями или неприятными ощущениями в середине грудной клетки, конечностях или спине, то есть наличие болей также можно использовать в качестве параметра для построения модели прогнозирования болезни сердца.

Распространенная практика использования нейросетевых методов моделирования может быть применена и в данной сфере для автоматизации и повышения качества диагностики сердечных заболеваний. Нейросетевое моделирование позволяет быстро провести анализ множества записей, на которые у человека ушли бы часы, и выявить закономерности, позволяющие эффективно моделировать предметную область [4].

Целью данной работы является разработка модели для прогнозирования болезни сердца на основе имеющихся медицинских показаний человека.

При определении входных данных модели были выбраны следующие параметры:

- x_1 – Возраст;
- x_2 – пол (1 – мужской, 0 – женский);
- x_3 – отсутствие боли (1 – утверждение истинно, 0 – утверждение ложно);
- x_4 – боли как при стабильной стенокардии (1 – утверждение истинно, 0 – утверждение ложно);
- x_5 – боли как при нестабильной стенокардии (1 – утверждение истинно, 0 – утверждение ложно);
- x_6 – другие боли (1 – утверждение истинно, 0 – утверждение ложно);
- x_7 – давление в покое;
- x_8 – холестерин в крови [мг/дл];
- x_9 – сахар в крови [мг/дл];
- x_{10} – гипертрофия левого желудочка по результатам ЭКГ (1 – утверждение истинно, 0 – утверждение ложно);
- x_{11} – нормальный результат ЭКГ (1 – утверждение истинно, 0 – утверждение ложно);
- x_{12} – аритмия по результатам ЭКГ (1 – утверждение истинно, 0 – утверждение ложно);
- x_{13} – максимальный пульс при нагрузке;
- x_{14} – проявление стенокардии при нагрузке (1 – утверждение истинно, 0 – утверждение ложно);
- x_{15} – изменение ST участка при нагрузке (1 – утверждение истинно, 0 – утверждение ложно);

x_{16} – характер изменения ST участка: выпуклость вверх (1 – утверждение истинно, 0 – утверждение ложно);

x_{17} – характер изменения ST участка: плоское изменение (1 – утверждение истинно, 0 – утверждение ложно);

x_{18} – характер изменения ST участка: выпуклость вниз (1 – утверждение истинно, 0 – утверждение ложно);

x_{19} – число крупных сосудов выявленных рентгеноскопией;

x_{20} – тестирование таллием: дефект, возможно восстановление (1 – утверждение истинно, 0 – утверждение ложно);

x_{21} – тестирование таллием: норма (1 – утверждение истинно, 0 – утверждение ложно);

x_{22} – тестирование таллием: дефект (1 – утверждение истинно, 0 – утверждение ложно);

На выходе переменная y , обозначающая наличие болезни сердца у человека, где 1 – человек здоров, 0 – имеется болезнь сердца.

Были использованы данные с сайта [5]. Данные содержат 303 записи о состоянии здоровья различных людей. Далее записи были случайным образом разделены на три множества: обучающее – 207 записей; тестирующее – 79 записей; и подтверждающее множество – 17 записей.

В ходе работы при помощи нейросимулятора [6] была спроектирована, обучена и протестирована нейронная сеть, реализующая модель предметной области. С помощью следствия из теоремы Арнольда-Колмогорова-Хельт-Нильсона было определено изначальное необходимое количество нейронов на скрытом слое двуслойной нейронной сети (т.е. с одним скрытым слоем) [4]. На двадцать два входных нейрона и один выходной нейрон с 207 примерами в обучающем множестве количество нейронов могло быть от 3 до 250, при среднем количестве нейронов равному 127.

Ошибка обобщения для такой сети составила в лучшем случае 40,68%, однако ошибка на обучающем множестве составляла около 10,18%. Таким образом был сделан вывод, что модель подвержена переобучению. Чтобы сделать модель менее устойчивой было решено увеличить количество слоев и нейронов.

Для определения новой архитектуры было решено использовать перебор гиперпараметров сети. Был проведен перебор следующих гиперпараметров: функция активации (линейная, сигмоида, гиперболический тангенс), количество слоев (от одного до пяти), количество нейронов на каждом слое (от десяти до ста с шагом десять). Наилучший результат был достигнут при четырех скрытых слоях с семью нейронами и функцией активации – гиперболический тангенс. Архитектура сети представлена на рисунке (см. рис. 1) Результат составил 29,86% – ошибка обобщения и 25,73% – ошибка на обучающем множестве.




Рисунок 1. Архитектура сети

Затем было решено изучить значимость параметров и уменьшить количество входных параметров, чтобы модель была более зависима от наиболее значимых параметров. В результате были удалены параметры x_2 , x_3 , x_{11} , x_{13} , x_{17} , x_{21} . В основном это избыточные параметры, так как есть другие параметры, содержащие информацию об этом параметре. Например, отсутствие дефекта при тесте таллием будет в случае, если в параметрах x_{22} и x_{20} будут стоять нули. То есть таким образом были убраны повторяющиеся параметры.

Затем модель вновь была обучена на данных. После обучения с меньшим количеством параметров ошибка обучения составила 12,89%, ошибка обобщения 15%. Результаты проверки адекватности модели на подтверждающем множестве представлены на диаграмме ниже (рис. 2). Проверка модели на адекватность показала погрешность в 1,53%, модель предсказала всё максимально точно, с небольшими сомнениями при постановке диагнозов.




Рисунок 2. Результаты проверки модели

Тестирование разработанной нейронной сети показало, что она является достаточно точной и адекватной математической моделью, поэтому её можно использовать для исследования законов предметной области – наличия или отсутствия болезни сердца у человека.

Наиболее значимым параметром (рис 3.) на обучающем множестве был определен параметр, говорящий о количестве крупных сосудов.




Рисунок 3. Важность параметров

В ходе работы был создан инструмент, который можно использовать для предварительной диагностики сердечно-сосудистых заболеваний человека.

Библиографический список

1. Е. Б. Искаков (2017) Распространенность факторов риска развития сердечно-сосудистых заболеваний // Медицина и экология. № 3. С 17-24.
2. Ясницкий Л. Н., Думлер А. А., Полещук А. Н., Богданов К. В., Черепанов Ф. М. Нейросетевая система экспресс-диагностики сердечно-сосудистых заболеваний // Пермский медицинский журнал. 2011. Т. 28. № 4. С. 77-86.
3. Сердечно-сосудистые заболевания (2017) // Сайт Всемирной организации здравоохранения [https://www.who.int/ru/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/ru/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) Просмотрено: 3.12.2019
4. Ясницкий Л. Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
5. Kaggle – Heart Disease UCI. [Электронный ресурс] [Режим доступа: <https://www.kaggle.com/ronitf/heart-disease-uci>] [Проверено: 3.12.2019].
6. Черепанов Ф. М., Ясницкий Л. Н. Свидетельство об отраслевой регистрации разработки №8756. Симулятор нейронных сетей «Нейросимулятор 1.0» // Зарегистрировано в Отраслевом фонде алгоритмов и программ 12.07.2007.

HEART DICEASE DIAGNOSIS BASED ON NEURAL NETWORK

Startsev Daniil S.,

National Research University Higher School of Economics, Russia, Perm, 614046,
Students kaya str., 38, startsevdsk@gmail.com

This article describes process of development of math model based on neural network simulator for heart disease diagnosis, as well as testing and proving its adequacy. After developing model, it was found that the number of blood vessels has the most influence on diagnosis heart disease.

Keywords: disease, heart, prediction, model, neural network.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗА ОПАСНЫХ МЕТЕОРОЛОГИЧЕСКИХ УСЛОВИЙ

*Быков Алексей Васильевич, Вакорин Антон Романович,
Ветров Андрей Леонидович, Ясницкий Леонид Нахимович*
Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15.

В статье представлено описание разработки нейросетевой системы для прогнозирования вероятности наступления неблагоприятных погодных условий. Система позволяет прогнозировать возможность наступления неблагоприятных погодных условий с учетом метеорологических показателей.

Ключевые слова: искусственный интеллект, нейросетевые технологии, метеорология, прогноз погоды.

Введение. Прогнозирование погоды в современном мире является одной из тех тем, которой заинтересованы представители многих сфер жизни людей. Опасные погодные явления не только приносят экономический ущерб, но и создают опасности для человеческой жизни.

На данный момент известно небольшое число исследований, направленных на решение проблемы прогнозирования погоды средствами нейросетевого моделирования. Важность решения этой проблемы подчеркивают недавние публикации зарубежных исследователей [1-4]. В данных работах отмечается высокая эффективность и значительное уменьшение ошибки при использовании нейросетей, в сравнении с традиционными подходами.

Этой темой также интересуются и российские исследователи. По данной теме была защищена кандидатская диссертация [5] и опубликованы статьи [6-8], в которых показана высокая точность прогнозирования погоды при использовании нейронных сетей.

В результате анализа литературных источников [1-8], был выбран следующий набор показателей: X1 – отметка времени (0 или 12 часов), X2-X18 – *adv_ept_850* (адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа), X19-X35 – *cape90* (потенциальная доступная энергия неустойчивости перемешанного слоя (Дж/кг)), X36-X52 – *cape180* (потенциальная доступная энергия неустойчивости наиболее неустойчивого перемешанного слоя (Дж/кг)), X53-X69 – *cape255* (потенциальная доступная энергия неустойчивости наиболее неустойчивого слоя (Дж/кг)), X70-X86 – *cin* (энергия противодействия конвекции (Дж/кг)), X87-X103 – *dci* (индекс глубокой конвекции), X104-X120 – *dls* (сдвиг ветра в слое 0,5 км – 6 км), X121-X137 – *dpt_2m* (температура точки росы на высоте

2м), X138-X154 – hgt_300 (высота изобарической поверхности 300 гПа), X155-X171 – hgt_500 (высота изобарической поверхности 500 гПа), X172-X188 – hgt_700 (высота изобарической поверхности 700 гПа), X189-X205 – hgt_850 (высота изобарической поверхности 850 гПа), X206-X222 – hgt_925 (высота изобарической поверхности 925 гПа), X223-X239 – ki (индекс Вайтинга), X240-X256 – li (индекс плавучести) X257-X273 – li120 (индекс плавучести наиболее неустойчивого перемешанного слоя), X274-X290 – tmp_300 (температура изобарической поверхности 300 гПа), X291-X307 – tmp_500 (температура изобарической поверхности 500 гПа), X308-X324 – tmp_700 (температура изобарической поверхности 700 гПа), X325-X341 – tmp_850 (температура изобарической поверхности 850 гПа), X342-X358 – tmp_925 (температура изобарической поверхности 925 гПа), X359-X375 – u_300 (широтная компонента вектора скорости ветра на изобарической поверхности 300 гПа), X376-X392 – u_500 (широтная компонента вектора скорости ветра на изобарической поверхности 500 гПа), X393-X409 – u_700 (широтная компонента вектора скорости ветра на изобарической поверхности 700 гПа), X410-X426 – u_850 (широтная компонента вектора скорости ветра на изобарической поверхности 850 гПа), X427-X443 – u_925 (широтная компонента вектора скорости ветра на изобарической поверхности 925 гПа), X444-X460 – v_300 (долготная компонента вектора скорости ветра на изобарической поверхности 300 гПа), X450-X477 – v_500 (долготная компонента вектора скорости ветра на изобарической поверхности 500 гПа), X478-X494 – v_700 (долготная компонента вектора скорости ветра на изобарической поверхности 700 гПа), X495-X511 – v_850 (долготная компонента вектора скорости ветра на изобарической поверхности 850 гПа), X512-X528 – v_925 (долготная компонента вектора скорости ветра на изобарической поверхности 925 гПа), X529-X545 – vvel_500 (скорость вертикальных движений на изобарической поверхности 500 гПа), X546-X562 – vvel_700 (скорость вертикальных движений на изобарической поверхности 700 гПа), X563-X579 – vvel_850 (скорость вертикальных движений на изобарической поверхности 850 гПа), X580-X596 – vvel_925 (скорость вертикальных движений на изобарической поверхности 925 гПа), X597-X613 – rh_300 (относительная влажность воздуха на изобарической поверхности 300 гПа), X614-X630 – rh_500 (относительная влажность воздуха на изобарической поверхности 500 гПа), X631-X647 – rh_700 (относительная влажность воздуха на изобарической поверхности 700 гПа), X648-X664 – rh_850 (относительная влажность воздуха на изобарической поверхности 850 гПа), X665-X681 – rh_925 (относительная влажность воздуха на изобарической поверхности 925 гПа).

Выходной параметр D1 – наличие неблагоприятных погодных условий в следующие 27 часов после наблюдения (0-отсутствие/1-наличие).

Каждый метеорологический показатель собирался в 17 точках размера 13x13 км изображенных на рисунке 1.

В отличие от работ [6, 8], для обучения нейросети предлагается использовать большее количество входных параметров, для повышения

точности прогноза. Такими дополнительными параметрами являются: adv_ert_850 (адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа), care90 (потенциальная доступная энергия неустойчивости перемешанного слоя), care180 (потенциальная доступная энергия неустойчивости наиболее неустойчивого перемешанного слоя), care255 (потенциальная доступная энергия неустойчивости наиболее неустойчивого слоя), cin (энергия противодействия конвекции), X87-X103 – dci (индекс глубокой конвекции), dls (сдвиг ветра в слое 0,5 км – 6 км), dpt_2m (температура точки росы на высоте 2м), hgt_300 (высота изобарической поверхности 300 гПа), hgt_500 (высота изобарической поверхности 500 гПа), hgt_700 (высота изобарической поверхности 700 гПа), hgt_850 (высота изобарической поверхности 850 гПа), hgt_925 (высота изобарической поверхности 925 гПа), ki (индекс Вайтинга), X240-X256 – li (индекс плавучести) li120 (индекс плавучести наиболее неустойчивого перемешанного слоя), rh_300 (относительная влажность воздуха на изобарической поверхности 300 гПа), rh_500 (относительная влажность воздуха на изобарической поверхности 500 гПа), rh_700 (относительная влажность воздуха на изобарической поверхности 700 гПа), rh_850 (относительная влажность воздуха на изобарической поверхности 850 гПа), rh_925 (относительная влажность воздуха на изобарической поверхности 925 гПа).

Множество погодных показателей, было взято из архивов атмосферной модели NCEP-CFS (США), в точках, представленных на рисунке 1. Собранные данные охватывают период май-сентябрь 1998-2018 года.

Перед переходом к проектированию и обучению нейросетевой модели, была выполнена очистка исходного множества от противоречивых примеров, выбросов, дубликатов. Также для устранения перекоса было проведено сокращение исходного множества. В результате, объем итогового множества включал 98 примеров. Данное множество было разделено на обучающее и тестирующее в соотношении 90% и 10% соответственно.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [9] по методике [10]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имел 681 входных нейронов, один выходной нейрон и один скрытый слой с двумя нейронами.

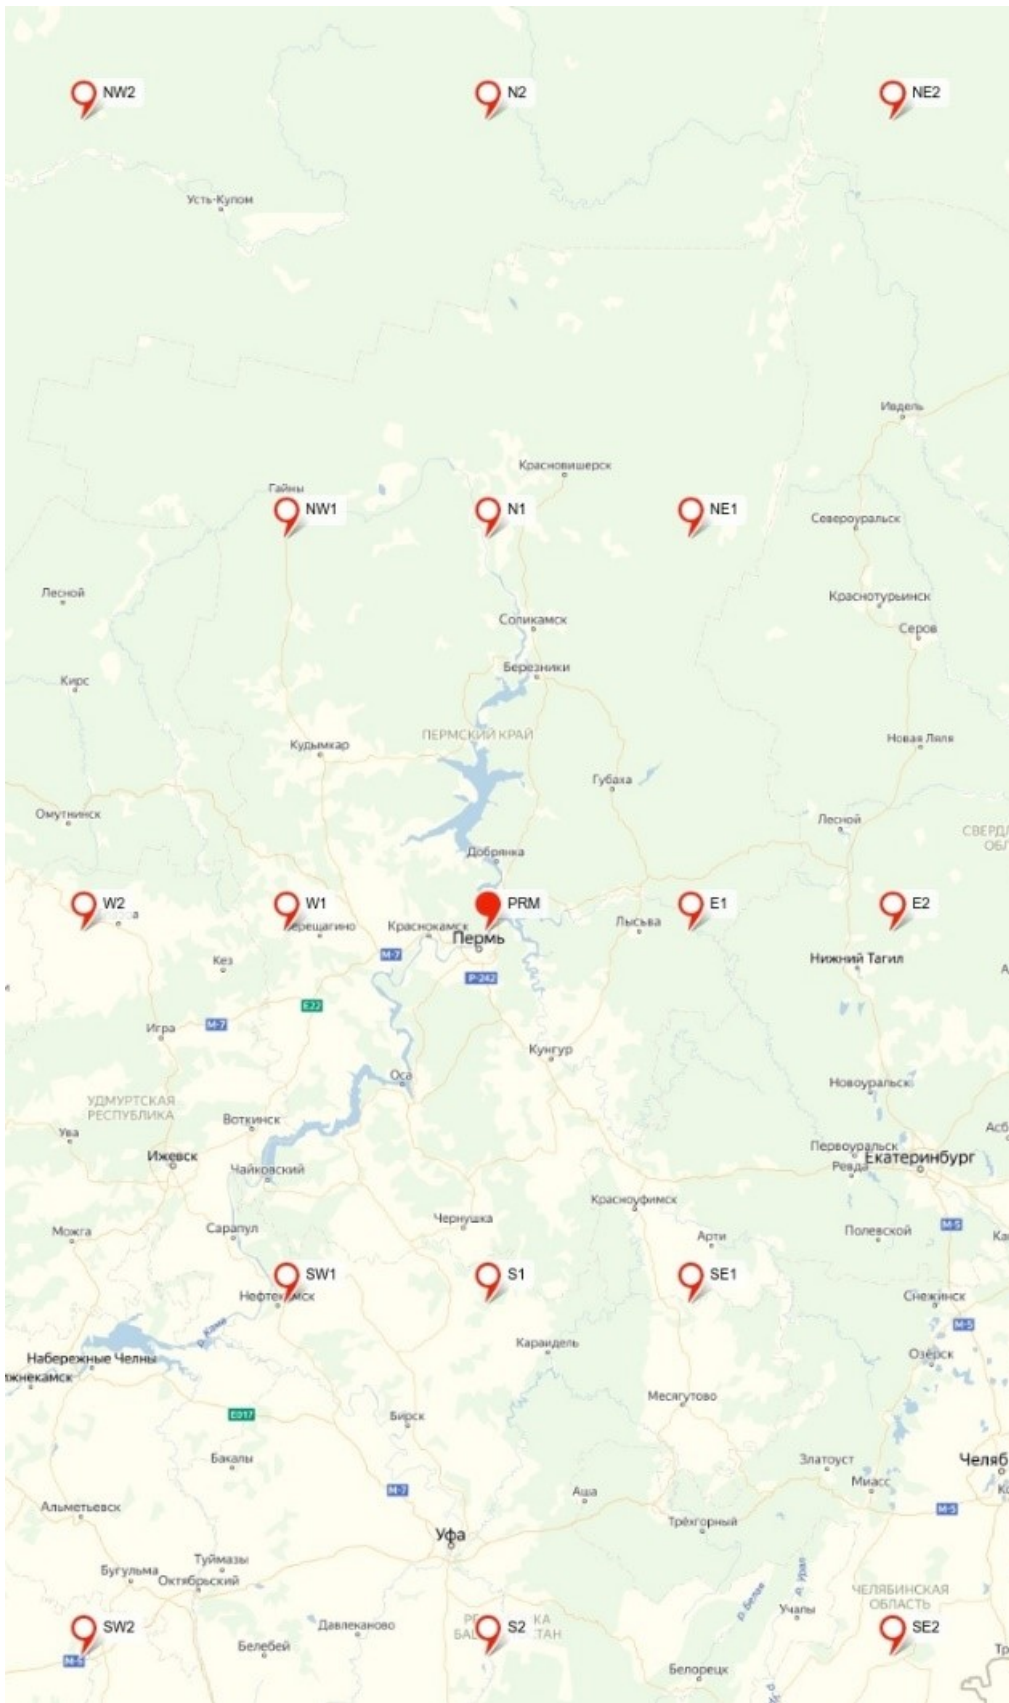


Рисунок 1. Точки сбора данных на географической карте

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 10 примеров. Средняя ошибка тестирования составила 0,16%, что можно считать приемлемым

результатом. На рисунке 2 представлена гистограмма, демонстрирующая минимальную разницу между фактической и прогнозируемой нейросетью вероятности наступления неблагоприятных погодных условий (для краткости штормов) 10 ситуаций из тестирующего множества. Таким образом, тестирование нейронной сети позволяет сделать вывод о ее адекватности моделируемой предметной области.



Рисунок 2. Результат тестирования нейронной сети

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рисунке 3.




Рисунок 3. Значимость входных параметров нейросетевой модели

Как видно из рисунка 3, наиболее значимыми являются группы параметров adv_ept_850 (адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа), vvel_850 (скорость

вертикальных движений на изобарической поверхности 850 гПа), cin (энергия противодействия конвекции (Дж/кг)), X87-X103 – dci (индекс глубокой конвекции), u_{300} (широтная компонента вектора скорости ветра на изобарической поверхности 300 гПа), rh_{850} (относительная влажность воздуха на изобарической поверхности 850 гПа), u_{700} (широтная компонента вектора скорости ветра на изобарической поверхности 700 гПа), rh_{925} (относительная влажность воздуха на изобарической поверхности 925 гПа), hgt_{850} (высота изобарической поверхности 850 гПа), rh_{500} (относительная влажность воздуха на изобарической поверхности 500 гПа). Это можно объяснить тем, что на возможность образования неблагоприятных погодных условий в большей степени влияет высокое давление и большая скорость ветра.

Далее было произведено сокращение исходного множества параметров до 51 параметра. Сокращение проводилось в 14 раундов, в ходе каждого раунда строилась адекватная нейросеть и вычислялась значимость её параметров. После этого параметры с нулевой значимостью исключались из множества. Процесс сокращения числа параметров иллюстрирует рисунок 4.



Рисунок 4. Число параметров каждой версии нейросети

В результате в множестве параметров остались группы: adv_ept_{850} (адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа), cin (энергия противодействия конвекции), rh_{700} (относительная влажность воздуха на изобарической поверхности 700 гПа).

Далее было проведено исследование полученной нейросети на соответствие законам предметной области. Исследование производилось с помощью метода «замораживания» [10], суть которого заключается в варьировании значения одного параметра при фиксированных значениях всех остальных параметров. Для этой цели были отобраны ситуации, в которых нет неблагоприятных погодных условий (штормов), т.е. значение выходного параметра $D1=0$. Их количество составило 83.

На рисунке 5 показан график зависимости количества прогнозов неблагоприятных погодных условий (штормов) от значения параметра X12 ($adv_ept_850_s2$ – адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа в точке юг 4°). Как следует из графика, увеличение значения этого параметра с 0 до 0,001 ведёт к повышению вероятности наступления неблагоприятных погодных условий (штормов) с нуля до $\frac{74}{83} \times 100\% = 89,1\%$




Рисунок 5. Результат прогнозирования нейросети при увеличении входного параметра X12 ($adv_ept_850_s2$ – адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа в точке юг 4°) с 0 до 0,001. Вероятность шторма: 89,1%

На рисунках 6-9 продемонстрирована зависимость количества прогнозов неблагоприятных погодных условий (штормов) от значения параметра X40 (rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°). В этом случае прослеживается тенденция к увеличению вероятности наступления неблагоприятных погодных условий (штормов), от относительной влажности с нуля при различных значениях до 85,5% при значении 180.




Рисунок 6. Прогноз нейросети при увеличении входного параметра X40 (rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°) до 100. Вероятность шторма: 30,1%




Рисунок 7. Прогноз нейросети при увеличении входного параметра X40 (rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°) до 120. Вероятность шторма: 60,2%




Рисунок 8. Прогноз нейросети при увеличении входного параметра X40 (rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°) до 140. Вероятность шторма: 72,3%




Рисунок 9. Прогноз нейросети при увеличении входного параметра X40 (rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°) до 180. Вероятность шторма 85,5%

Далее аналогичным методом было проведено исследование параметра X49 (rh_700_se2 – относительной влажности на высоте 700 гПа, в точке юго-восток, 4°). На рисунках 10-13 продемонстрирована зависимость количества прогнозов неблагоприятных погодных условий (штормов) от значения этого параметра.




Рисунок 10. Прогноз нейросети при увеличении входного параметра X49 (rh_700_se2 – относительной влажности на высоте 700 гПа, в точке юго-восток, 4°) до 100. Вероятность шторма: 19,3%




Рисунок 11. Прогноз нейросети при увеличении входного параметра X49 (rh_700_se2 – относительной влажности на высоте 700 гПа, в точке юго-восток, 4°) до 120. Вероятность шторма: 30,1%




Рисунок 12. Прогноз нейросети при увеличении входного параметра X49 (rh_700_se2 – относительной влажности на высоте 700 гПа, в точке юго-восток, 4°) до 140. Вероятность шторма: 37,3%




Рисунок 13. Прогноз нейросети при увеличении входного параметра X49 (rh_700_se2 – относительной влажности на высоте 700 гПа, в точке юго-восток, 4°) до 180. Вероятность шторма: 54,2%

На рисунке 14 приведена гистограмма, обобщающая полученные результаты. Как видно из рисунка, увеличение значений исследованных параметров атмосферы приводит к увеличению вероятности возникновения опасных погодных явлений в городе Перми. Однако это влияние проявляется в разной степени.




Рисунок 14. Сводная гистограмма эффектов от изменения параметров:

- X12 – adv_ept_850_s2 – адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа в точке юг 4°.
- X40 – rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°.
- X49 – rh_700_se2 – относительной влажности на высоте 700 гПа, в точке юго-восток, 4°.

Следует заметить, что, в отличии от результатов, приведенных в статьях [6, 8] в данной работе наиболее значимыми показателями оказались:

X12 (adv_ept_850_s2 – адвекция эквивалентно-потенциальной температуры на изобарической поверхности 850 гПа в точке юг 4°);

X40 (rh_700_ne1 – относительная влажность на высоте 700 гПа, в точке северо-восток, 2°);

X49 (rh_700_se2 – относительная влажность на высоте 700 гПа, в точке юго-восток, 4°).

Заключение. Построена система нейросетевого оценивания вероятности наступления неблагоприятных погодных условий на примере г. Перми. С помощью разработанной нейросетевой модели выявлен комплекс метеорологических параметров, достаточный для высокоточного прогноза. Методом сценарного прогнозирования построены графики зависимостей вероятности наступления неблагоприятных погодных условий от наиболее значимых метеорологических параметров.

Библиографический список

1. Kim S., Pan S., Mase H. Artificial neural network-based storm surge forecast model: Practical application to Sakai Minato, Japan. Applied Ocean Research. Volume 91, October 2019.
2. Baboo S. S., Shereef I. K. An efficient weather forecasting system using artificial neural network //International journal of environmental science and development. – 2010. – Т. 1. – №. 4. – С. 321.
3. Abhishek K. et al. Weather forecasting model using artificial neural network //Procedia Technology. – 2012. – Т. 4. – С. 311-318.
4. Tripathy A. K. et al. Weather forecasting using ANN and PSO //Int. J. Sci. Eng. Res. – 2011. – Т. 2. – С. 1-5.
5. Грибин А.С. Применение алгоритмов искусственных нейронных сетей для краткосрочного метеопрогноза: дис. ... кандидат физико-математических наук: 25.00.30. – Российский государственный гидрометеорологический университет, Санкт-Петербург, 2005 – 145 с.
6. Андреева Е. С. Применение методов нейропрограммирования для определения рисков опасных явлений погоды // Известия высших учебных заведений. Северо-Кавказский регион. Естественные науки. – 2008. – №. 5.
7. Саиян С. А., Лезина И. В. Использование нейронных сетей на основе многослойного персептрона для прогнозирования статистических данных на примере погоды // Актуальные проблемы авиации и космонавтики. – 2013. – Т. 1. – №. 9. – С. 381-382.
8. Цуриков А. Н. Применение нейросетевой технологии для определения класса устойчивости атмосферы // Актуальные проблемы гуманитарных и естественных наук. – 2013. – №. 4. – С. 65-70.
9. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
10. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

DYNAMIC NEURAL NETWORK SYSTEM FOR EVALUATING THE SECONDARY MARKET OF RESIDENTIAL REAL ESTATE OF THE CITY OF NIZHNY NOVGOROD

*Bykov Alexey V., Vakorin Anton R.,
Vetrov Andrey L., Yasnitsky Leonid N.*
Perm State University
Str. Bukireva, 15, Perm, Russia, 614990

The article describes the development of a neural network system for predicting the likelihood of adverse weather conditions. The system allows people to forecast the probability of adverse weather conditions considering meteorological indicators.

Keywords: artificial intelligence, neural network technologies, meteorology, weather forecast.

УДК 159.923.3, 004.032.26

ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОГНОЗИРОВАНИИ СКЛОННОСТИ ЧЕЛОВЕКА К ПРОКРАСТИНАЦИИ

Трегубова Ирина Дмитриевна

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, uxore3ka@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования склонности человека к прокрастинации. Система позволяет определять склонность человека к прокрастинации с учетом параметров, как отражающих, так и не отражающих психическую деятельность человека. Было проведено ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: искусственный интеллект, нейронная сеть, прокрастинация, затягивание.

Введение. Явление патологического затягивания выполнения задач известно давно, об «откладывающих все дела на завтра» писали ещё древние авторы. В научном обиходе термин появился в 1977 году, когда одновременно вышли две научные статьи: «Прокрастинация в жизни человека» [2] и «Преодоление прокрастинации» [3]. Но что же такое прокрастинация?

Прокрастинация (от англ. *procrastination* «задержка, откладывание»; от лат. *procrastinatio* с тем же значением, восходит к *cras* «завтра» или

crastinum «завтрашний» + pro- «для, ради») – в психологии склонность к постоянному откладыванию даже важных и срочных дел, приводящая к жизненным проблемам и болезненным психологическим эффектам.

Прокрастинация проявляется в том, что человек, осознавая необходимость выполнения вполне конкретных важных дел (например, своих должностных обязанностей), пренебрегает этой необходимостью и отвлекает своё внимание на бытовые мелочи или развлечения.

Проблема прокрастинации актуальна, так как в той или иной мере, это состояние знакомо большинству людей и до определённого уровня считается нормальным.

Поиск причин прокрастинации.

Причины и механизмы возникновения прокрастинации изучаются до сих пор. Существует множество исследований, в которых установлены корреляции показателей уровня выраженности данного феномена с низкой самооценкой, отсутствием уверенности в себе, плохим самоконтролем, высокой склонностью к перфекционизму, импульсивностью, депрессией и тревогой [13, 14, 15, 16]. Например, в ходе проведения исследования [8] была доказана гипотеза о существовании связи между перфекционизмом и прокрастинацией, выражающаяся в отрицательной зависимости прокрастинации от перфекционизма.

Ряд авторов связывают прокрастинацию со страхами, связанными с выполнением дела и с прогнозируемыми последствиями их выполнения. Так, причиной откладывания может быть неуверенность в том, что дело удастся выполнить должным образом и результат будет принят и одобрен окружающими (Solomon, L. J., & Rothblum, E. D., 1984).

Исследование [12] выявило, что генетические, анатомические и функциональные различия влияют на характерную прокрастинацию независимо друг от друга. Например, через эстроген женщины могут быть более чувствительными к генетически обусловленным различиям дофаминовой концентрации, что, в свою очередь, проявляется в поведении.

Новое исследование Университета Колорадо [11], опубликованное в журнале *Psychological Science*, утверждает о том, что прокрастинация обусловлена генетически. Те же генетические факторы отвечают и за склонность к импульсивности. Регулирует прокрастинацию и импульсивность генетический механизм, влияющий на нашу способность ставить себе первоочередные цели и эффективно контролировать с их помощью наши действия.

Нейронные сети в психодиагностике.

Современные нейронные сети представляют собой программно-аппаратные средства создания специализированных моделей и устройств и позволяют решать широкий круг задач диагностики на основе применения алгоритмов теории распознавания образов. К достоинствам нейросетей следует отнести их относительную простоту, нелинейность, работу с нечеткой информацией, нескритичность к исходным данным, способность обучаться на материале конкретных примеров [7].

Впервые возможность применения искусственных нейронных сетей в области психодиагностики показана в серии работ М.Г. Доррера, А.Н. Горбаня, А.Г. Копытова, В.И. Зенкина [9, 10]. Данные работы посвящены исследованию вопроса о возможности развития психологической интуиции у нейросетевых экспертных систем. Авторами впервые была проведена работа по оптимизации структуры психодиагностических методик на основе исследования механизма психологической интуиции программных нейроимитаторов. Результаты представляют интерес для теории создания психодиагностических методик, позволяют рекомендовать нейронные сети для применения в данной области [9].

Инновационными в области психодиагностики были работы Е.В. Левченко, А.Ю. Калугина, И.А. Митрофанова и С.А. Кузнецовой [19, 20, 21], продемонстрировавших эффективность применения нейронных сетей в психологических исследованиях, в частности, для создания тестов, предназначенных для определения уровня психологического благополучия, выявления волевых качеств, выявления предрасположенности к депрессивному состоянию.

С тех пор в психодиагностике не раз использовался механизм искусственных нейронных сетей. Пермским отделением Научного совета РАН по методологии уже получен ряд положительных результатов в создании интеллектуальных систем, предназначенных для выявления предрасположенностей людей к наркомании [17], суициду, насилию [18].

Методика.

Для построения нейронной сети в первую очередь необходимо определить и учесть множества входных и выходных параметров.

Чтобы достоверно оценить уровень прокрастинации каждого человека, была выбрана «Шкала общей прокрастинации» (General Procrastination Scale) С.Н. Lay [13], позволяющая определять степень выраженности склонности откладывать дела «на потом».

В данном опросе испытуемому предлагается ответить на 20 вопросов. Каждый вопрос оценивается по 5-балльной шкале Лайкерта (1 – совершенно не характерно, 2 – не характерно, 3 – нейтрально, 4 – характерно, 5 – абсолютно характерно).

Прямые значения: вопросы 1, 2, 5, 7, 9, 10, 12, 16, 17, 19.

Реверсивные значения: вопросы 3, 4, 6, 8, 11, 13, 14, 15, 18, 20.

Для определения уровня прокрастинации высчитывается суммарный балл путем сложения баллов за каждый ответ, при этом баллы, проставленные респондентом в ответ на реверсивные пункты, инвертируются, т.е. 5 баллов заменяются на 1 балл, 4 балла – на 2 балла и т.п.

Шкала К. Лэя была переведена, апробирована и модифицирована под российскую действительность О.С. Вендекер и М.В. Осатиной в 2014 году [4].

Стандартные нормы для Шкалы общей прокрастинации по О.С. Вендекер и М.В. Осатиной следующие: до 30 баллов – крайне низкие

показатели, от 30 до 42 баллов – низкие, от 43 до 67 баллов – средние, от 68 до 80 – высокие, от 81 балла – очень высокие значения.

Полный текст опросника содержится в приложении А.

Кроме параметров из шкалы Лэя, были взяты те, которые не связаны с психической деятельностью человека:

- Пол,
- Возраст,
- Знак зодиака.

А также параметры, которые возможно являются причинами прокрастинации:

- Наличие вредных привычек,
- Импульсивность,
- Перфекционизм,
- Страх или другие негативные чувства перед началом работы.

В результате данного анализа, был выбран следующий набор входных параметров:

X1 – Пол (1 – мужской, 2 – женский);

X2 – Возраст (не кодируется);

X3 – Знак зодиака (1 – овен, 2 – телец, ..., 12 – рыбы);

X4 – Наличие вредных привычек (1 – да, 0 – нет);

X5 – Склонны ли вы к импульсивности? (5 – да, 4 – скорее да, 3 – средне, 2 – скорее нет, 1 – нет);

X6 – Склонны ли вы к перфекционизму? (1 – да, 2 – скорее да, 3 – средне, 4 – скорее нет, 5 – нет);

X7 – Испытываете ли вы чувство усталости, раздражения, неуверенности или страха перед началом работы? (2 – да, 1 – иногда, 0 – нет);

X8 – X27 – Вопросы из методики «Шкала общей прокрастинации» К. Лэя (Прямые вопросы: 1 – совершенно не характерно, 2 – не характерно, 3 – нейтрально, 4 – характерно, 5 – абсолютно характерно; Обратные вопросы: 5 – совершенно не характерно, 4 – не характерно, 3 – нейтрально, 2 – характерно, 1 – абсолютно характерно).

Выходным параметром является уровень прокрастинации, полученный по шкале Лэя: D1 – уровень прокрастинации (0 – отсутствие прокрастинации, 1 – легкая прокрастинация, 2 – умеренное проявление прокрастинации, 3 – серьезная прокрастинация, 4 – тяжелая прокрастинация).

Итоговое множество для нейросети содержит данные о 125 респондентах. Данные были получены с помощью опроса [1]. Данные о параметрах X4 – X7 были получены с помощью «лобовых» вопросов опроса. Этот способ является ненадежным по причине эффекта социальной желательности (стремление респондентов давать такие ответы, которые, с их точки зрения, выглядят предпочтительнее в глазах окружающих). Однако в данной работе было принято считать ответы респондентов в большей степени объективными.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [5] по методике [6]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет 27 входных нейронов, один выходной и один скрытый слой с десятью нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 15 примеров. Средняя ошибка тестирования составила 14%. На Рисунок 18 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью уровнем прокрастинации респондентов из тестирующего множества.




Рисунок 18. Результат тестирования нейронной сети

Из результатов, изображенных на Рисунок 18, можно сделать вывод об адекватной работе спроектированной нейронной сети.

Рисунок 19 представляет гистограмму, показывающую распределение значимости параметров. Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5» [5].




Рисунок 19. Значимость входных параметров нейросетевой модели

Самыми значимыми входными параметрами оказались: оценки импульсивности и перфекционизма, знак зодиака и некоторые вопросы из шкалы Лэя.

Дальнейшая цель исследования – выяснение характера влияния различных входных параметров модели на результат моделирования, т.е. на предрасположенность человека к прокрастинации. Исследование производилось с помощью метода «замораживания», суть которого заключается в изменении значения одного параметра и фиксации значений всех других параметров. Данный метод позволяет выявить влияние исследуемого параметра на выходной. Для этой цели были отобраны 5 респондентов, информация о которых отражена в Таблица 7.

Таблица 7 – Характеристики респондентов, выбранных для исследования

Входной параметр	Респондент №1	Респондент №2	Респондент №3	Респондент №4	Респондент №5
X1	1	2	2	1	2
X2	60	20	18	30	28
X3	7	6	7	4	4
X4	0	0	1	1	1
X5	4	5	4	5	3
X6	4	1	5	3	3
X7	0	2	1	1	1
X8	4	5	3	3	3
X9	2	1	3	3	2
X10	1	2	4	1	2

Входной параметр	Респондент №1	Респондент №2	Респондент №3	Респондент №4	Респондент №5
X11	1	5	4	4	5
X12	1	2	2	1	2
X13	3	4	2	2	2
X14	3	4	4	2	4
X15	2	5	2	1	3
X16	1	5	3	2	3
X17	1	4	2	1	2
X18	1	4	4	5	3
X19	1	5	4	4	2
X20	1	4	3	1	2
X21	5	5	2	3	3
X22	2	5	5	3	3
X23	3	5	4	4	4
X24	1	4	2	4	3
X25	3	5	4	1	3
X26	1	4	4	1	2
X27	1	5	4	1	2

На Рисунок 20 изображена гистограмма, отражающая зависимость уровня прокрастинации человека от ответа на вопрос №3 шкалы Лэя.




Рисунок 20. Зависимость уровня прокрастинации от ответа на вопрос №3 шкалы Лэя

Можно заметить, что уровень прокрастинации увеличивается, если респонденту не характерно делать приготовления заранее.

Рисунок 21 продемонстрирует связь между прокрастинацией и перфекционизмом, выражающаяся в положительной зависимости прокрастинации от перфекционизма.




Рисунок 21. Зависимость прокрастинации от перфекционизма

Возраст относится к наименее значимым параметрам нейронной сети, но изначально он был включен в опрос, чтобы оценить влияние параметра, который не отражает психическую деятельность человека, на уровень прокрастинации. Из Рисунок 22 мы можем заметить тенденцию снижения уровня прокрастинации с увеличением возраста человека.




Рисунок 22. Зависимость прокрастинации от возраста

Следующим предметом исследования является вопрос №20 шкалы Лэя. На Рисунок 23 изображена диаграмма, отражающая данную зависимость. По графику видно, что в 80% случаев уровень прокрастинации растет, если

человеку не характерно выполнять все необходимые дела до вечернего отдыха.




Рисунок 23. Зависимость уровня прокрастинации от ответа на вопрос №20 шкалы Лэя

Последним исследуемым параметром является пол человека. Этот параметр не является наиболее значимым, но в исследовании Рурского университета [12] было выявлено, что женщины из-за более высокого уровня дофамина могут быть склонны к откладыванию дел. Поэтому также было проверено влияние данного параметра (пола) в полученной нейронной сети.




Рисунок 24. Зависимость уровня прокрастинации от пола человека

Рисунок 24 не демонстрирует какой-либо конкретной зависимости уровня прокрастинации от пола человека, но можно наблюдать следующее: Респонденты №2, 3, и 5 – женщины, но если бы они были мужчинами, то их уровень прокрастинации слегка бы снизился. Респонденты №1 и 4 – мужчины, но будь они женщинами, их уровень тоже бы снизился.

Нельзя утверждать, что между полом человека и уровнем прокрастинации есть зависимость, но можно заметить, что при смене пола респондентов уровень прокрастинации снижается.

Заключение. Построена нейросетевая система, предназначенная для прогнозирования склонности человека к прокрастинации. В отличие от уже существующих методик определения уровня прокрастинации, предложенная модель также содержит параметры, которые не отражают психическую деятельность человека. Проведены исследования параметров максимально и минимально влияющих на уровень прокрастинации. Представленная модель была обучена на небольшом наборе данных с некоторым количеством субъективных ответов, поэтому ее дальнейшее обучение и более надежные методы оценивания некоторых параметров (импульсивность, перфекционизм) могут сделать модель более полной и обнаружить новые зависимости.

Автор выражает благодарность за ценные консультации доктору психологических наук профессору Елене Васильевне Левченко.

Библиографический список

1. URL: <https://forms.gle/vnEduk5rRVS4LHUh9>
2. Steel P. The Nature of Procrastination: A Meta-Analytic and Theoretical Review of Quintessential Self-Regulatory Failure // *Psychological Bulletin*. – 2007. – № 133(1). – P. 65–94.
3. Ellis A., Knaus W.J. *Overcoming procrastination*. – New York: Signet Books, 1977.
4. Виндекер О.С., Останина М.В. Формальный и содержательный анализ шкалы общей прокрастинации С.Н. Lay (на примере студенческой выборки) // *Актуальные проблемы психологического знания: теоретические и практические проблемы психологии*. – 2014. – № 1(30). – С. 116–126.
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
6. Ясницкий Л.Н. *Интеллектуальные системы*. – М.: Лаборатория знаний, 2016. – 221 с.
7. Березин М.А., Пашков С.В. Опыт применения искусственных нейронных сетей для целей дифференциальной диагностики и прогноза нарушений психической адаптации // *Вестник ЮУрГУ. Серия: Компьютерные технологии, управление, радиоэлектроника*. 2006. №14 (69). URL: <https://cyberleninka.ru/article/n/opyt-primeneniya-iskusstvennyh->

- neuronnyh-setey-dlya-tseley-differentsialnoy-diagnostiki-i-prognoza-narusheniy-psihicheskoy-adaptatsii (дата обращения: 20.06.2020).
8. Гукалова Ю.В. ВКР: Перфекционизм и прокрастинация у молодых предпринимателей города Владивостока. – Владивосток, 2018 – URL: <https://nauchkor.ru/uploads/documents/5b8ecbdb7966e1073081bbda.pdf>
 9. Доррер М.Г., Горбань А.Н., Копытов А.Г., Зенкин В.И. Психологическая интуиция нейронных сетей // Нейроинформатика и ее приложения: Материалы III Всероссийского рабочего семинара. – Красноярск: КГТУ, 1995. – с.114-127.
 10. Доррер М.Г. Попытка применения нейронных сетей для прогнозирования психологической совместимости в группе // Нейроинформатика и ее приложения: Программа и тезисы докладов II Всероссийского рабочего семинара. – Красноярск: КГТУ, 1994. – С. 13.
 11. Gustavson D. E., Miyake A., Hewitt J. K., Friedman N. P. (2014). Genetic Relations Among Procrastination, Impulsivity, and Goal-Management Ability: Implications for the Evolutionary Origin of Procrastination. *Psychological Science*, 25(6), 1178–1188. URL: <https://doi.org/10.1177/0956797614526260>
 12. Schlüter C., Arning L., Fraenz C., Friedrich P., Pinnow M., Güntürkün O., Beste C., Ocklenburg S., Genc E., Genetic variation in dopamine availability modulates the self-reported level of action control in a sex-dependent manner, *Social Cognitive and Affective Neuroscience*, Volume 14, Issue 7, July 2019, Pages 759–768, URL: <https://doi.org/10.1093/scan/nsz049>
 13. Lay C. (1986). At last, my research article on procrastination. *Journal of Research in Personality*, 20, 474-495.
 14. Тащилина Е.А. Исследование прокрастинации и перфекционизма у студентов университета различных направлений подготовки: диссертация магистра психологии. Екатеринбург. Уральский Федеральный Университет им. Б.Н. Ельцина, Екатеринбург, 2014.
 15. Ильин Е.П. Работа и личность: трудоголизм, перфекционизм и лень / Е.П. Ильин. – Санкт-Петербург: Питер, 2011.
 16. Ferrari J.R. Self-handicapping by procrastinators: Effects of task importance and performance privacy: Doctoral dissertation, Adelphi University, Garden City. – NY, 1990.
 17. Ясницкий Л.Н., Грацилёв В.И., Куляшова Ю.С., Черепанов Ф.М. Возможности моделирования предрасположенности к наркозависимости методами искусственного интеллекта // Вестник Пермского университета. Философия. Психология. Социология. 2015. Вып. 1(21). С. 61–73.
 18. Ясницкий Л.Н. Использование методов искусственного интеллекта в изучении личности серийных убийц / Л.Н. Ясницкий, С.В. Ваулева, Д.Н. Сафонова, Ф.М. Черепанов // Криминологический журнал Байкальского государственного университета экономики и права. – 2015. – Т. 9, № 3. – С. 423–430. – DOI: 10.17150/1996-7756.2015.9(3).423-430.

19. Левченко Е.В., Митрофанов И.А., Ясницкий Л.Н. Нейросетевое моделирование феномена депрессии // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. Научн.-практ. конф. (г. Пермь, 14-18 мая 2018 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2018. С. 139 – 143.
20. Левченко Е.В., Кузнецова С.А., Ясницкий Л.Н. Использование методов искусственного интеллекта в диагностике эмоционально-волевой сферы личности // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. Научн.-практ. конф. (г. Пермь, 14-18 мая 2018 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2018. С. 136 – 139.
21. Калугин А.Ю. Использование нейронных сетей в психологических исследованиях. // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. Научн.-практ. конф. (г. Пермь, 14-18 мая 2018 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2018. С. 144 – 148.

ПРИЛОЖЕНИЕ А

«Шкала общей прокрастинации» С. Lay

Инструкция. Для описания собственной личности люди могут использовать разные характеристики. Определите, пожалуйста, насколько характерно или не характерно для Вас каждое из следующих утверждений. Для этого используйте пятибалльную систему ответов. В колонке с правой стороны укажите балл, наилучшим образом характеризующий Вас.

- 1 балл – в высшей степени не характерно;
- 2 балла – в умеренной степени не характерно;
- 3 балла – нейтрально (утверждение никак Вас не характеризует);
- 4 балла – в умеренной степени характерно;
- 5 баллов – в высшей степени характерно.

1. Я часто ловлю себя на том, что выполняю задания, которые намеревался сделать несколько дней назад	
2. Я часто пропускаю концерты, спортивные соревнования и подобные мероприятия, потому что не успеваю купить билеты вовремя	
3. Планируя вечеринку, я делаю необходимые приготовления заранее	
4. Когда пора вставать утром, я чаще всего сразу встаю с кровати	
5. Написанное мною письмо может лежать несколько дней, пока я его отправлю	
6. Как правило, я своевременно делаю ответные телефонные звонки	
7. Работу, которая требует чуть больше, чем просто сидеть и делать ее, я откладываю на несколько дней	
8. Я, как правило, принимаю решения как можно скорее	
9. Я, как правило, откладываю начало работы, которую нужно выполнять	
10. Во время путешествия мне обычно приходится спешить в сборах, чтобы прибыть в аэропорт или на вокзал к нужному времени	
11. Когда я готовлюсь к выходу из дома, я редко спохватываюсь что-нибудь доделывать в последнюю минуту	

12. Когда близится срок завершения работы, я часто впустую трачу время на другие вещи	
13. Если мне приходит счет на небольшую сумму, я оплачиваю его сразу же	
14. Обычно я даю ответ на приглашение очень быстро	
15. Я часто выполняю задания раньше, чем это необходимо	
16. Я часто завершаю покупку подарков к дню рождения или Новому году в последнюю минуту	
17. Даже важные вещи я часто покупаю в последнюю минуту	
18. Я, как правило, выполняю все запланированные на день дела	
19. Я постоянно говорю: «Я сделаю это завтра»	
20. Я обычно проверяю, все ли необходимое я сделал, до того, как вечером устроюсь отдохнуть	

Прямые значения: вопросы 1, 2, 5, 7, 9, 10, 12, 16, 17, 19.

Реверсивные значения: вопросы 3, 4, 6, 8, 11, 13, 14, 15, 18, 20.

Стандартные нормы для Шкалы общей прокрастинации по О. С. Вендекер и М. В. Осатиной следующие:

- до 30 баллов – крайне низкие показатели,
- от 30 до 42 баллов – низкие,
- от 43 до 67 баллов – средние,
- от 68 до 80 – высокие,
- от 81 балла – очень высокие значения.

USING ARTIFICIAL INTELLIGENCE METHODS IN PREDICTING A PERSON'S PROCRASTINATION PROPENSITY

Tregubova Irina D.

Perm State University,

Str. Bukireva, 15, Perm, Russia, 614990, yxore3ka@gmail.com

The article describes the development of a neural network system for predicting a person's procrastination tendency. The system allows you to determine a person's propensity for procrastination, taking into account parameters that both reflect and do not reflect the person's mental activity. A number of studies have been conducted, the results of which are presented in this article.

Key words: artificial intelligence, neural network, procrastination, procrastination, protraction.

НЕЙРОСЕТЕВЫЕ СТРУКТУРЫ С ЛАТЕНТНЫМИ ПЕРЕМЕННЫМИ В ПРОГНОЗИРОВАНИИ СОСТОЯНИЯ ЖИВЫХ СИСТЕМ

*Протасова Зейнаб Усама, Медников Дмитрий Андреевич,
Шаталова Ольга Владимировна*

Юго-Западный государственный университет,
305040, Россия, г. Курск, ул. 50 лет Октября, 94, Shatolg@mail.ru

Для прогнозирования функционального состояния живых систем предложено дополнить гетерогенные решающие модули виртуальными потоками. Виртуальный поток представлен моделью латентного предиктора, отражающей скрытые связи в системе между латентными и действительными предикторами. Исходя из этого, вектор информативных признаков будет представлен двумя подвекторами. Первый будет соответствовать виртуальным потокам (латентным переменным), а второй – реальным потокам. Анализ классификаций качества принятия решений гетерогенными классификаторами по определению вероятности повторного инфаркта миокарда на репрезентативных контрольных выборках с применением ROC-кривых показал, что при использовании моделей латентных предикторов в гетерогенных классификаторах, диагностическая чувствительность и диагностической специфичности повышаются на 5...8%.

Ключевые слова: виртуальный поток, предиктор, нейронная сеть, классификатор.

Введение. При прогнозировании перехода живых систем из одного состояния в другое необходимо учитывать их латентные переменные, которые не входят в исследуемый комплект предикторов систем, на основе которых строятся их прогностические модели. Для учета этих предикторов необходима надсистемная надстройка с самоорганизующейся структурой [1, 2, 3, 4, 5].

Для построения системной надстройки, которая реализует работу с виртуальными потоками данных и интегрирует их в данные натурального эксперимента, необходим соответствующий инструментарий, а также алгоритмы и методы, позволяющие реализовать модель виртуального потока.

Модели и методы. В качестве инструментария для формирования виртуальных потоков используем обучаемые нейронные сети [6, 7, 8]. Экспертные знания в этих системах рационально представлять по сегментам (потокам). Это позволяет экспертной системе делать заключения в виде коэффициентов уверенности по выдвигаемой гипотезе в пределах одного решающего модуля. Для объединения экспертных знаний по гетерогенным

решающим модулям (потокам) используются обучаемые нейронные сети [9, 10].

На выходе решающего модуля получаем скалярную величину – коэффициент уверенности для данного участка информативных признаков, (частный коэффициент уверенности) [11, 12]. Агрегация частных коэффициентов уверенности производится на основе обучаемого классификатора. В роли обучаемого классификатора часто выступает нейронная сеть [6, 10]. В случае, когда коэффициенты уверенности, полученные на основе алгоритмов нечеткого вывода, используются в качестве входных данных нейронной сети, появляются проблемы с получением необходимой точности классификации нейронной сети, которая используется на входе решающего модуля. Это связано с тем, что полученные на основе экспертных заключений и гипотез признаки, которые формируются на входе нейронной сети, могут неадекватно отражать внутренние процессы в исследуемой системе. Только эксперт (ЛПР) способен определить полноту признакового пространства и релевантность самих признаков. Обучаемая нейронная сеть, на вход которой подаются эти признаки, вносит свои искажения в интерпретацию признакового пространства. Так как сформировать достаточно большой объем выборки весьма проблематично, то во избежание переобучения нейронной сети, вносятся дополнительные связи, позволяющие придать больший вес статистическим данным в общем процессе синтеза интеллектуальной системы прогнозирования состояния живых систем.

Экспериментальные исследования выборок, сформированных искусственно, показали, что ввод («включение») дополнительного информативного признака (входа) в нейронную сеть прямого распространения с двумя входами способна увеличить точность двухальтернативной классификации до значения в 100% и выше, при разнице первых моментов у третьего признака всего лишь на 10% [13, 14].

Суть метода синтеза виртуального потока состоит в том, чтобы сначала модифицировать саму обучающую выборку с помощью управления статистическими характеристиками виртуальных данных, а затем, на основе уже преобразованных данных обучающей выборки, производится перенастройка самой нейронной сети. Данные действия могут нести итерационный характер [15, 16].

Метод синтеза виртуального потока для нейронной сети прямого распространения (рисунок 1) реализуется с помощью последовательности следующих итерационных шагов, управление которыми осуществляется посредством трехпозиционного ключа K .

На *первом шаге* ключ K в положении 2, сумматор 4 работает как повторитель, а виртуальный вход z_{N+1} исполняет функции поляризующего входа для нейронной сети $NET1$. Нейронная сеть $NET1$ настраивается на обучающей выборке

$$\{\tilde{Z}_1, \tilde{Z}_2, \dots, \tilde{Z}_i, \dots, \tilde{Z}_M\}, \quad (1)$$

где

$$\tilde{Z}_i = (z_1, z_2, \dots, z_j, \dots, z_N, z_{N+1})^T, \quad (2)$$

$$\forall i \quad z_{N+1}^i = 0,5.$$

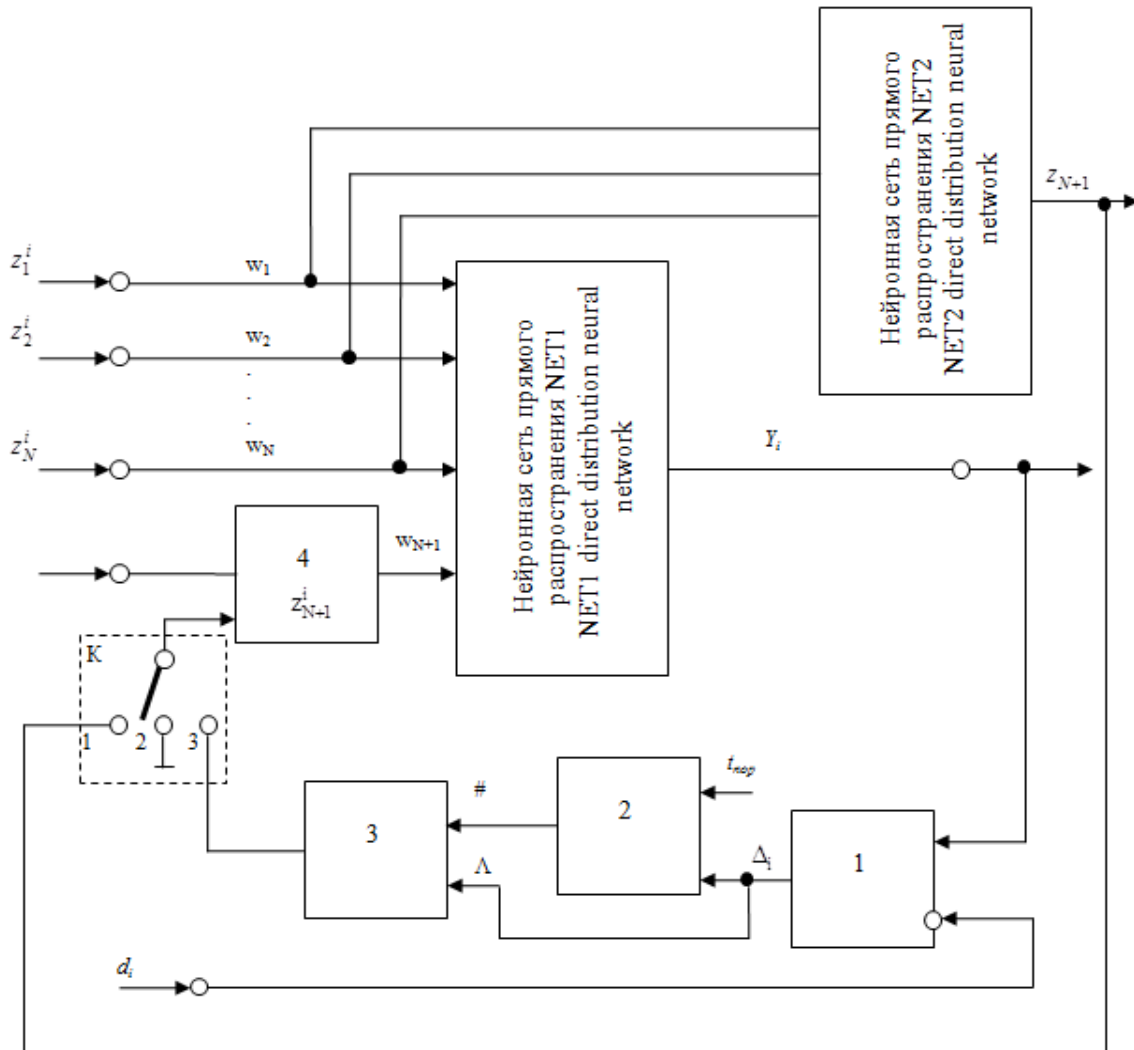


Рисунок 2. Схема синтеза виртуального потока

На *втором шаге* ключ K в положении 3. На этом шаге происходит искусственное повышение качества классификации полученной модели нейронной сети $NET1$ посредством управления виртуальным входом $(N+1)$. Улучшение показателей качества классификации достигается при помощи изменения вспомогательного информативного признака в экземплярах обучающей (контрольной) выборки, как это показано на структурной схеме. В схеме присутствует петля отрицательной обратной связи, которая реализована с помощью последовательного соединения блоков 1 (блоков вычисления ошибки)

$$\Delta_i = Y_i - d_i, \quad (3)$$

где Y_i – выход $NET1$, d_i – класс, к которому относится i -й образец обучающей (контрольной) выборки;

блоком 2 –компаратор, блока 3 – блок управления и блока 4 – сумматор.

Необходимость коррекции добавочного элемента вектора информативных признаков (компоненты $N+1$) обусловлена тем, что в процессе поступления экземпляров обучающей выборки на вход $NET1$ в блоке 1 вычисляется ошибка классификации (3). Блок управления 3 подбирает такие значения на входе сумматора 4, чтобы минимизировать ошибку (3). При этом значение выхода блока 3, минимизирующее (3), сохраняется в виде массива

$$\hat{Z}_{N+1} = (z_{N+1}^1, z_{N+1}^2, \dots, z_{N+1}^i, \dots, z_{N+1}^M)^T, \quad (4)$$

который используется для настройки нейронной сети $NET2$ в качестве функции цели.

Таким образом, на основе обучающей выборки происходит формирование новой обучающей выборки (1). При формировании обучающей выборки к каждому i – му N - мерному вектору Z_i добавляется z_{N+1} компонента, которая соответствует виртуальному потоку. Учитывая соответствие входов нейронной сети выходам гетерогенных решающих модулей, лежащих в диапазоне $0 \dots 1$, присваиваем вспомогательной $(N+1)$ -й координате всех экземпляров значение $0,5$, независимо от класса.

На *третьем шаге* строится модель латентного предиктора. Модель строится как аппроксиматор

$$z_{N+1}^i = f(z_1^i, z_2^i, \dots, z_N^i), \quad (5)$$

где i – номер образца контрольной выборки (неизвестного образца).

При построении модели (4) используется нейронная сеть прямого распространения $NET2$. Полученный на втором шаге массив (4) используется в качестве обучающей выборки для обучения этой сети. В этом случае первые N компонентов векторов, принадлежащих множеству (1), являются независимыми переменными. При этом зависимой переменной (функции цели) будут являться компоненты $N+1$ векторов, принадлежащих множеству (1).

На *четвертом шаге* происходит формирование решающего модуля, который используется для классификации неизвестного образца. Работа модуля заключается в перемещении ключа K в положение 1, что дает нам возможность использовать две нейронные сети $NET1$ и $NET2$ одновременно (классификатор и аппроксиматор соответственно).

Аппроксиматор, необходимый для формирования виртуального потока в режиме «Классификация», создает вектор со структурой (1), используя вектор признаков неизвестного образца со структурой.

Результаты. В качестве прикладной задачи для интеллектуальной системы прогнозирования с виртуальными потоками решалась задача прогнозирования повторного инфаркта миокарда (ПИМ). В качестве дополнительного решающего модуля был введен решающий модуль с виртуальным потоком, построенный согласно базовой структуры, представленной на рисунке 1. Всего в системе использовалось пять гетерогенных классификаторов, из выходов которых формировался виртуальный поток согласно вышеописанному методу [15, 16].

Для оценки качества прогнозирования интеллектуальной системы с гетерогенными классификаторами была сформирована экспериментальная группа из больных, перенесших острый инфаркт миокарда (ОИМ). В экспериментальную группу входило 230 больных, мужчин и женщин в возрасте от 40 до 75 лет, перенесших впервые ОИМ. Исследование носило ретро-проспективный характер. Больные наблюдались в течении двух лет.

Оценка эффективности полученных результатов проводилась с помощью ROC-кривых (ROC – Receiver operating characteristic), что позволило дать оценить качество модели по разделению двух классов. Для решения задачи ROC-анализа были определены классификационные пороги. Для определения пороговых значений использовались показатели характеризующие риск появления ПИМ в качестве шкал для построения гистограмм распределения классов ω_0 и $\omega_1 = \omega_{ИМ}$. Шкала ASCORE была использована как прототип для гетерогенного классификатора [17, 18].

Рисунок 2 демонстрирует сравнительные характеристики гетерогенных классификаторов на ROC-плоскости. Анализ графиков сравнительных характеристик гетерогенных классификаторов, представленных на рисунке 5, относительно ROC-плоскости позволяет оценить вклад каждой группы информативных признаков в общий процесс прогнозирования.




Рисунок 2. ROC-кривые двух гетерогенных классификаторов

На основании результатов проведенных наблюдений были проанализированы различные показатели, которые позволяют охарактеризовать состояние исследуемой категории больных с учетом разработанных методов и средств (работа с использованием интеллектуальной системы поддержки принятия решений врача-кардиолога) и без них. Результаты проверки на контрольной выборке эффективности работы правил прогнозирования ПИМ в период реабилитации на основании комплексного учета информативных признаков показывают приемлемое для практики качество решения поставленных в работе целей и решаемых задач.

Заключение. Выполнен анализ качества принятия решений гетерогенными классификаторами по оценке степени риска повторного инфаркта миокарда на репрезентативных контрольных выборках с применением ROC – кривых. Проведено исследование пяти гетерогенных классификаторов с учетом последовательного роста числа решающих модулей, включенных в классификационную модель. Осуществлена сравнительная оценка качества показателей прогнозирования полученной модели классификатора с известной шкалой прогнозирования риска сердечно-сосудистых осложнений ASCORE. При использовании всех решающих модулей в гетерогенном классификаторе и диагностической специфичности 0,86 получена диагностическая чувствительность 0,90. Данный показатель в среднем, на 15% выше, чем у шкалы ASCORE и на 5-10% выше, чем у гетерогенного классификатора с отключенным виртуальным потоком.

Благодарность. Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 19-38-90116.

Acknowledgments: The reported study was funded by RFBR, project number 19-38-90116.

Библиографический список

1. Шуткин А.Н., Позин А.О., Филист С.А. Адаптируемые к структуре данных классификаторы в задачах прогнозирования профессиональных заболеваний // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Второй Всерос. науч.-практ. конф. Пермь: Перм. гос. нац. исслед. ун-т, 2017. С.161-164.
2. Филист С.А. Метод классификации сложных объектов на основе анализа структурных функций медленных волн / С.А. Филист, И.И. Волков, С.Г. Емельянов // Биомедицинская радиоэлектроника. №4. 2012. С.6-11.
3. Мохаммед А.А., Филист С.А., Шаталова О.В. Моделирование импеданса биоматериалов в среде MATLAB // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2013. № 4. С. 73-78.
4. Томакова Р.А., Шаталова О.В., Томаков М.В. Теоретико-множественный подход и теория графов в обработке сложноструктурируемых изображений : монография. Курск: Юго-Западный гос. ун-т, 2012. 119 с.
5. Петрова, Т.В. Распределенные автономные интеллектуальные агенты для мониторинга и мета-анализа эффективности управления живыми системами / Т.В. Петрова, А.А. Кузьмин, Д.Ю. Савинов и др. // Прикаспийский журнал: управление и высокие технологии. – 2017. – № 4 (40). – С. 61-73.
6. Филист С.А., Курочкин А.Г., Жилин В.В., и др. Использование гибридных нейросетевых моделей для многоагентных систем классификации в гетерогенном пространстве информативных признаков // Прикаспийский журнал: управление и высокие технологии. Научно-технический журнал. 2015. № 3 (31). С.85-95.
7. Филист С.А., Томакова Р.А., Яа Зар До Универсальные сетевые модели для задач классификации биомедицинских данных // Известия Юго-Западного государственного университета. 2012. № 4 (43). Ч. 2. С. 44-50.
8. Старцев Е.А., Шаталова О.В., Уварова В.В. Двумерные нейросетевые структуры мета-анализа медико-экологических данных // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. науч.-практ. конф. Пермь: Перм. гос. нац. исслед. ун-т., 2016. С.161-164.
9. Хайкин С. Нейронные сети: полный курс. 2-е изд., испр.: Пер. с англ. – М.: ООО «И.Д. Вильямс», 2006.- 1104 с.
10. Филист, С.А. Гибридная нейронная сеть с макрослоями для медицинских приложений/ С.А. Филист, О.В. Шаталова, М.А. Ефремов // Нейрокомпьютеры. Разработка и применение, 2014. – №6. – С. 35-39.

11. Кореневский Н.А., Филист С.А., Красковский А.Б. и др. Теория проектирования нечетких сетевых экспертных систем для управления медико-экологической безопасностью // Научные ведомости Белгородского государственного университета. Серия: История. Политология. Экономика. Информатика. 2009. № 9-1 (64). Том 11. С.146-151.
12. Жилин В.В., Филист С.А., Халед Абдул Рахим, Шаталова О.В. Способ моделирования нечетких моделей в пакете MATLAB для биомедицинских приложений // Медицинская техника. 2008. №2. С. 15-17.
13. Позин, А.О. Синтез дополнительного информативного признака для нейронной сети прямого распространения / А.О. Позин, С.А. Филист, А.Н. Шуткин и др. // Новые решения в области упрочняющих технологий: взгляд молодых специалистов: сборник научных статей по материалам Международной научно-практической конференции. – Курск: ЗАО «Университетская книга», 2016. – С. 212 – 217.
14. Позин, А.О. Тестирующие гибридные системы с дополнительным пространством информативных признаков / А.О. Позин, С.А. Филист, А.Н. Шуткин // Современные информационные технологии в управлении качеством: сборник статей V Международной научно-прикладной конференции. – Пенза: Приволжский Дом знаний, 2016. – С.46-50.
15. Киселев, А.В. Нейросетевые модули с виртуальными потоками для классификации и прогнозирования функционального состояния сложных систем/ А.В. Киселев, Т.В. Петрова, С.В. Дегтярев и др. // Известия Юго-Западного государственного университета.– 2018. – Т.22, №4. – С. 123-134.
16. Киселев, А.В. Виртуальные потоки в гибридных решающих модулях классификации сложноструктурируемых данных / А.В. Киселев, С.А. Филист, О.В. Шаталова и др. // Прикаспийский журнал: управление и высокие технологии. – 2018. № 2 (42). С. 137-149.
17. Filist S.A. A method for creating fuzzy neural-network models using the matlab package for biomedical applications/ S.A. Filist, V.V. Zhilin, K.A. Rakhim, O.V. Shatalova //Biomedical Engineering. 2008. Т. 42. № 2. – С. 64-66.
18. Filist S.A. Bioimpedance skin condition monitoring during therapeutic and cosmetic procedures/ S.A. Filist, V.A. Aleksenko, A.A. Kuzmin //Biomedical Engineering. 2008. Т. 42. № 2. – С. 97-99.

NEURAL NETWORK STRUCTURES WITH LATENT VARIABLES IN PREDICTION OF THE STATE OF LIVING SYSTEMS

Protasova Zeinab U., Mednikov Dmitry A., Shatalova Olga V.

Southwest State University

305040, Russia, Kursk, st. 50 years of October, 94, Shatolg@mail.ru

To predict the functional state of living systems, it is proposed to supplement the heterogeneous decision modules with virtual flows. The virtual flow is represented by a latent predictor model that reflects the hidden connections in the system between latent and real predictors. Based on this, the vector of informative features will be represented by two subvectors. The first one will correspond to virtual threads (latent variables) and the second one will correspond to real threads. Analysis of classifications of the quality of decision-making by heterogeneous classifiers to determine the probability of recurrent myocardial infarction on representative control samples using ROC curves showed that when using models of latent predictors in heterogeneous classifiers, diagnostic sensitivity and diagnostic specificity increase by 5 ... 8%.

Keywords: virtual flow, predictor, neural network, classifier.

УДК 004.89; 629.33

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ РЕЙТИНГА ТЕЛЕВИЗИОННЫХ ПЕРЕДАЧ

Бурматов Александр Андреевич

Пермский государственный национальный исследовательский университет,
механико-математический ф-т, КМБ

614990, Россия, г. Пермь, ул. Букирева, 15, aburmatov@outlook.com

Описан опыт разработки и применения нейросетевой системы для прогнозирования рейтинга телевизионных передач на основе данных по телепередачам российских телеканалов. Определены параметры, имеющие наибольшее влияние на телевизионный рейтинг. Приведены компьютерные эксперименты с целью определения закономерностей в телевизионном вещании.

Ключевые слова: рейтинг телепередач, прогнозирование, рекомендации, нейронная сеть.

Телевизионный рейтинг – наиболее ценный показатель для телевидения, поскольку характеризует конкретное количество человек, выбирающих тот или иной телепроект от общей численности населения.

В последние десятилетия телевизионная среда становится всё более сложной, однако моделированию и прогнозированию телевизионного рейтинга уделяется мало внимания [1]. Тем не менее были попытки предсказывать рейтинг телепередач и устанавливать факторы, влияющие на рост или снижение рейтинга. Так, применялись регрессионные модели, logit-модели, исторические методы прогнозирования [2]. В качестве параметров для своих моделей исследователи выбирали такие характеристики телепередач, как тип телепрограммы, день, время, неделя выхода в эфир, длительность передачи, число лет на телевидении, привлекательность и другие [2].

В настоящей работе будет предпринята попытка применения нейросетевого метода моделирования для прогнозирования рейтинга телепередач.

При создании экономико-математической модели, предназначенной для прогнозирования рейтинга телевизионных передач, в число входных параметров нейронной сети были включены только те критерии, поиски которых не требуют большого количества времени и которые могут быть обработаны немедленно, без больших трудозатрат. В качестве обучающего множества были выбраны данные еженедельных ТОП-100 телепередач за 2019 год, представленных в открытом доступе компанией Media Score, которая занимается исследованиями телевизионного эфира [3]. Объем обучающей выборки составил 4600 примеров, 10% из которых вошли в тестовое множество. Таким образом, при разработке нейросетевой экономико-математической модели мы использовали следующие входные параметры и систему кодирования их значений:

- $x_1 - x_{12}$ – *Жанр телепередачи:*
- x_1 – Ежедневные новости
- x_2 – Информационно-аналитические передачи (комментарии)
- x_3 – Кинофильмы
- x_4 – Телесериалы
- x_5 – Юмористические передачи
- x_6 – Музыкальные программы
- x_7 – Познавательные программы
- x_8 – Социально-политические программы
- x_9 – Спортивные программы
- x_{10} – Развлекательные программы
- x_{11} – Детские передачи
- x_{12} – Документальные программы.
- $x_{13} - x_{19}$ – *День недели выхода телепередачи в эфир (с понедельника по воскресенье)*
- x_{20} – Выходной день
- x_{21} – Праздничный день
- x_{22} – Время начала передачи (доля от 24 ч)
- x_{23} – Время окончания передачи (доля от 24 ч)
- x_{24} – Длительность передачи (доля от 24 ч)

$x_{25} - x_{35}$ – Телевизионный канал, на котором выходит передача:

x_{25} – «Домашний»

x_{26} – «Карусель»

x_{27} – «МАТЧ ТВ»

x_{28} – «НТВ»

x_{29} – «Первый канал»

x_{30} – «Пятый канал»

x_{31} – «РЕН ТВ»

x_{32} – «Россия 1»

x_{33} – «СТС»

x_{34} – «ТВ ЦЕНТР»

x_{35} – «ТНТ»

Для прогнозирования использован метод нейросетевого моделирования [4, 5] и нейросимулятор [6].

В качестве выходного параметра y была принята величина рейтинга телепрограммы (среднее количество человек, смотревших телепрограмму), выраженное в процентах от общей численности исследуемой аудитории.

Оптимальная структура нейронной сети представляла собой персептрон, имеющий тридцать пять входных нейронов, два скрытых слоя с девятью и одним нейронами соответственно, а также один выходной нейрон. В качестве активационных функций нейронов скрытого слоя использовался тангенс гиперболический, выходного слоя – линейная функция, а в качестве алгоритма обучения – алгоритм упругого распространения.

Для оценки качества нейронной сети (рис. 1) использовалась среднеквадратичная относительная погрешность, которая на тестирующем множестве примеров составила 9,4%, а коэффициент детерминации 0,88. Поскольку примеры тестирующего множества не использовались при обучении нейронной сети, можно утверждать, что нейронная сеть усвоила закономерности моделируемой предметной области, и теперь ее можно использовать для проведения вычислительных экспериментов.




Рисунок 1. Адекватность модели

После того как работа нейронной сети проверена на тестовых примерах и, следовательно, подтверждена адекватность нейросетевой математической модели, можно приступать к ее исследованию. Обученная нейросетевая модель реагирует на изменение входных переменных и ведет себя так же, как вела бы себя сама предметная область.

Первый вопрос, на который можно получить ответ с помощью модели – выяснить значимость входных параметров, т. е. степень их влияния на результат моделирования – рейтинг телевизионных передач. Объективную оценку такого влияния можно получить, например, с помощью той же нейронной сети путем поочередного исключения входных параметров и наблюдением за погрешностью ее тестирования. Чем выше оказывается погрешность тестирования, тем значимее соответствующий исключенный параметр. Построенная таким способом гистограмма приведена на рис. 2. Высота столбцов соответствует погрешности тестирования, полученной при исключенном входном параметре, подписанном под столбцом, поэтому ее можно интерпретировать как значимость этого параметра.




Рисунок 2. Значимость входных параметров

Анализируя диаграмму, видим, что самым значимым параметром оказалось «Время начала передачи». Следующими по значимости идут: «Показ передачи на телеканале Россия 1» и «Время окончания передачи». Присутствие параметров-телеканалов на диаграмме значимости говорит о рейтинге самого канала, т. е. на каналах с более высокой значимостью рейтинг телепередачи будет выше, чем если бы её транслировали на менее популярных каналах. Можем сделать вывод, что самыми рейтинговыми каналами являются «Россия 1», «Первый канал» и «НТВ».

Варьируя входные параметры обученной нейронной сети и производя вычисления, можно сформировать конкретный список рекомендаций, способствующих увеличению рейтинга телепередач.

Первая серия экспериментов над нейросетевой моделью была проведена с целью выявления лучшего времени показа телепередачи определенного жанра, т. е. времени, когда больше всего телезрителей смотрят программу. На рис. 3 и рис. 4 отображается зависимость рейтинга передачи от временных интервалов, когда она находится в эфире. Нетрудно заметить, что передачи любого телевизионного жанра имеют наибольший рейтинг в вечернее время.

На основе результатов данного эксперимента можно отметить программы, пользующиеся у телезрителей наибольшей популярностью. В будни телезрители отдают предпочтение новостям и информационно-аналитическим программам, телесериалам и спортивным передачам. В праздничные дни люди больше предпочитают смотреть новости, кинофильмы, юмористические и развлекательные программы.

Особо стоит отметить полученный результат в отношении развлекательных передач: в праздничный день они имеют большую популярность среди зрителей в любое время дня, тогда как у остальных жанров отмечается рост рейтинга в вечернее время.




Рисунок 3. Зависимость рейтинга телепередачи от времени дня трансляции в праздничные дни




Рисунок 4. Зависимость рейтинга телепередачи от времени дня трансляции в будние дни

Второй эксперимент был основан на исследовании рейтинга передачи в зависимости от её продолжительности. На примере телеканалов «Первый канал» и «Россия 1» (показано на рис. 5 и рис. 6 соответственно) мы установили, что поклонникам канала «Россия 1» больше интересны длительные передачи (это могут быть, например, телесериалы), причем такая тенденция прослеживается как в будние, так и в праздничные дни. Зрители же «Первого канала» с равным интересом смотрят как короткие, так и длинные программы, однако в будние дни (по непонятным нам причинам) их больше интересуют длительные передачи.




Рисунок 5. Зависимость рейтинга телепередачи на «Первом канале» от её длительности




Рисунок 6. Зависимость рейтинга телепередачи на «России 1» от её длительности

Разработана нейросетевая экономико-математическая модель, предназначенная для прогнозирования рейтинга телепередачи. Модель может быть использована телевизионными компаниями при планировании сетки вещания и сотрудниками рекламных агентств для выбора более подходящего канала для размещения рекламных роликов.

Исходя из описанных выше экспериментов, можно говорить о том, что метод нейросетевого моделирования можно использовать как для прогнозирования рейтинга телевизионных передач, так и для исследования закономерностей в телевизионном вещании.

Библиографический список

1. Danaher P., Dagger T. Using a nested logit model to forecast television ratings // International Journal of Forecasting, 28 (3), pp. 607-622.
2. Danaher P., Dagger T., Smith M. Forecasting television ratings // International Journal of Forecasting, 27 (4), pp. 1215-1240.
3. Mediascope : [сайт]. URL: <https://mediascope.net/>
4. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. 176 с.
5. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
6. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

NEURAL NETWORK FORECAST OF THE TV SHOW RATING

Burmatov Aleksandr A.

Perm State University

614990, Russia, Perm, street Bukireva, 15, aburmatov@outlook.com

This article describes the experience of developing and using a neural network system for predicting the rating of television programs based on data from television programs of Russian television channels. The parameters that have the greatest impact on the television rating are determined. Computer experiments are presented to determine patterns in television broadcasting.

Key words: tv show rating, forecasting, recommendations, neural network.

УДК 669.15-194.3

ПРОГНОЗИРОВАНИЕ ПРОЧНОСТИ СПЛАВА В ЗАВИСИМОСТИ ОТ ЛЕГИРУЮЩИХ ДОБАВОК

Пегушин Максим Сергеевич

Пермский государственный национальный исследовательский университет,
ПМИЭ, 614990, Россия, г. Пермь, ул. Букирева, 15, haker.alfike@yandex.ru

В статье представлено описание разработки нейросетевой системы для прогнозирования прочности сплавов в зависимости от легирующих добавок. Программа дает возможность изменять прочность сплавов, влиять на результаты путем корректировки процентного соотношения отдельных легирующих элементов.

Ключевые слова: промышленность, сплавы, легирующие элементы, нейронная сеть, прогноз.

Обзор предметной области. Одними из первых исследователей, занимавшихся этой темой был кандидат технических наук Тухватулин.И.Х в своей диссертации «Моделирование и разработка составов литейных износостойких сталей нейросетевым методом» [2]. Результатом данной работы стали четыре состава износостойких сталей.

Введение. Легированная сталь – сталь, которая, кроме обычных примесей, содержит элементы, специально вводимые в определённых количествах для обеспечения требуемых физических или механических свойств.

Легирующие добавки повышают прочность, коррозионную стойкость стали, снижают опасность хрупкого разрушения. Актуальность создания новых более крепких сплавов ясна и обусловлена тем, что легированные сплавы широко используются в промышленности, машиностроении и строительстве.

Целью работы является создание нейросетевой модели, и ее реализации в виде программной системы, позволяющей прогнозировать предел прочности легированных сталей при растяжении в зависимости от изменения соотношения легирующих добавок в сплаве. Создание такой модели снизит производственные издержки на создание сплавов, потому что эксперименты не будут требовать использование «реальных» ресурсов, а прогнозирование будет производиться на компьютере.

Методика моделирования. При построении нейросетевой модели в качестве входных параметров были использованы следующие 11 легированных добавок и 3 вида термической обработки.

X1 – Процентное содержание углерода в сплаве.

X2 – Процентное содержание хрома в сплаве.

X3 – Процентное содержание никеля в сплаве.

X4 – Процентное содержание молибдена в сплаве.

X5 – Процентное содержание титана в сплаве.

X6 – Процентное содержание вольфрама в сплаве.

X7 – Процентное содержание азота в сплаве.

X8 – Процентное содержание марганца в сплаве.

X9 – Процентное содержание бора в сплаве.

X10 – Процентное содержание ванадия в сплаве.

X11 – Процентное содержание кремния в сплаве.

X12 – Температура первой закалки стали в градусах Цельсия

X13 – Температура второй закалки стали в градусах Цельсия

X14 – Температура отпуска стали в градусах Цельсия

Y – Выходным параметром модели является предел прочности при растяжении, выраженный в кг/мм².

Всего были собраны данные о 81 стали. Информация о сталях, их прочностях и легирующих компонентах бралась их книги Данилевского В.В «Справочник молодого машиностроителя» [3]. Все множество было разделено, соответственно, на обучающее (66 сталей, приблизительно 80%), тестирующее (11 сталей, приблизительно 15 %), подтверждающее (4 стали,

приблизительно 5%). Проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью выполнялись с помощью нейропакета «Нейросимулятор 5.0» [1] по традиционной методике Пермского отделения Научного совета РАН по методологии искусственного интеллекта [4, 5]. Как видно из рис.1. структура нейронной сети представляла из собой персептрон, имеющий 14 входных нейронов, 1 скрытый слой, в котором 2 нейрона, а также один выходной нейрон. В качестве активационных функций входного, скрытого и выходного слоев использовался тангенс гиперболический, а в качестве алгоритма обучения – алгоритм упругого распространения.

Результат тестирования нейронной сети. После обучения нейронной сети с помощью обучающего множества (66 сталеи), ее прогностические «способности» проверялись на примерах тестирующего множества (11 сталеи), в которые в процессе обучения не участвовали. Средняя квадратичная относительная ошибка тестирования нейронной сети, вычисленная по формуле:

$$E = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - y_n)^2}{N}}}{|\max(d_n) - \min(d_n)|} 100\%$$

в которой N – количество элементов выборки, d_n – значение прочности при растяжении n-го сплава, y_n – её прогнозируемая величина.

В результате средняя квадратичная относительная ошибка тестирования нейронной сети составила 6.544%.




Рисунок 1. Сравнение ожидаемых и полученных значений прочности

Стоит отметить, что ожидаемые и полученные результаты прочности оказались практически одинаковыми, что отображено на рис.1.

Анализ влияния параметров на прочность. Прежде всего, по методике [6, 8] путем поочередного исключения входных нейронов и наблюдением за погрешностью сети была определена значимость входных параметров модели, т.е. – степень их влияния на результат моделирования




Рисунок 2. Значимость параметров

Как видно из рис.4, самым значимым параметром оказалось процентное содержание хрома в сплаве. Следующими по значимости идут: содержание углерода, вольфрама, а также температура первой закалки и отпуска.

Применение методов нейросетевого моделирования позволяет ставить над объектами виртуальные компьютерные эксперименты, что значительно упростит и удешевит процесс создания новых сплавов. Путем экспериментов, варьируя входные параметры обученной нейронной сети, можно изменять характеристики сплавов. В результате, можно сформировать список рекомендаций по изменению процентного содержания отдельных легирующих добавок для увеличения прочности сплава.

Проведем серию экспериментов над математической моделью стали 20ХН. Этот сплав имеет приблизительно среднюю прочность при растяжении. Компьютерные эксперименты с нейросетевой математической моделью выполнялись методом «замораживания» [9] – путем вычислений с помощью нейронной сети при постепенном изменении какого-либо одного из входных параметров и сохранении остальных входных параметров неизменными. В качестве изменяемых входных параметров, использовались наиболее значимые параметры, такие как хром, углерод и вольфрам. Также была выполнено прогнозирование прочности стали 20ХН, в зависимости от технологии изготовления, а именно, температура отпуска. На рис. 4 – 6

приведены результаты компьютерных экспериментов над сталью 20ХН с целью изучения влияния легирующих добавок на прочность стали. Оранжевым цветом выделим столбец, прочность и содержание легирующего вещества, которого соответствует действительным(заводским). Голубым цветом выделим остальные столбцы, они будут соответствовать прочности, которую мог бы приобрести сплав при изменении содержания легирующего элемента.




Рисунок 3. Прочность сплава в зависимости от содержания хрома

Как видно из рисунка, прочность стали растет с увеличением содержания хрома.




Рисунок 4. Прочность сплава в зависимости от содержания углерода

Увеличение содержание углерода в сплаве, увеличивает его прочность, однако, после 0,4-0,45 процентов углерода, увеличение этого легирующего элемента не целесообразно, так как показатели прочности практически остаются неизменными.




Рисунок 5. Прочность сплава в зависимости от содержания вольфрама

В случае с вольфрамом, его добавление лишь снизит прочность данного сплава.




Рисунок 6. Прочность сплава в зависимости от отпуска

Заключение. Разработанная нейросетевая математическая модель, позволяет прогнозировать прочность легирующих сплавов в зависимости от легирующих добавок и это может приводить как к улучшению, так и к ухудшению прочности сплава. Путем экспериментов возможно создание сплавов с новым составом.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0 //Свидетельство о государственной регистрации программы ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
2. Тухватулин.И.Х. Моделирование и разработка составов литейных износостойких сталей нейросетевым методом.
3. Данилевский В.В Справочник молодого машиностроителя.
4. Ясницкий Л.Н. Введение в искусственный интеллект. – М.: Издательский центр «Академия», 2005. – 176 с.
5. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. – 221с.
6. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
7. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
8. Ясницкий Л.Н., Данилевич Т.В. Современные проблемы науки. М.: БИНОМ. Лаборатория знаний, 2008. 294 с.
9. Sharda R., Delen D. Predicting box-office success of motion pictures with neural networks // Expert Systems with Applications. – 2006. – No 30. – Pp. 243-254.

FORECASTING THE STRENGTH OF THE ALLOY DEPENDING ON THE ALLOYING ADDITIVES

Pegushin Maxim S.

Perm State University

614990, Russia, Perm, street Bukireva, 15, haker.alfike@yandex.ru

The article describes the development of a neural network system for predicting the strength of alloys depending on alloying additives. The program makes it possible to change the strength of alloys, to influence the results by adjusting the percentage of individual alloying elements.

Key words: industry, alloys, alloying elements, neural network, forecast.

ПРОГНОЗИРОВАНИЕ РЕЗУЛЬТАТОВ СПОРТИВНЫХ СОБЫТИЙ ПРИ ПОМОЩИ НЕЙРОННЫХ СЕТЕЙ

Челпанов Василий Андреевич

Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15, vasya.chel@mail.ru

В статье представлено описание разработки нейросетевой системы для прогнозирования результатов команд Главной лиги бейсбола (MLB). Система позволяет предсказывать, выйдет ли команда в плей-офф по результатам, которые были показаны в течение регулярного сезона. В работе проведен ряд исследований, которые направлены на изучение применения нейронных систем в спорте.

Ключевые слова: спорт, бейсбол, спортивная аналитика, статистика, нейронная сеть, прогноз.

Введение. В настоящее время в спорте не все решается физической силой, упорством, волей к победе. Немаловажным фактором победы является статистика. Трудно поверить, но сейчас информация, которая была получена в результате спортивных соревнований, глубоко анализируется и в дальнейшем используется для достижения более высоких результатов. Например, до конца 90-ых годов статистика практически не использовалась в футболе, а сейчас все изменилось – на данный момент статистика неоценима при определении состава, изучении соперника и поиске игроков. Сегодня ни один футбольный матч высокого уровня не обходится без численного анализа, а тренеры все больше доверяют продвинутой статистике. И это неудивительно, ведь в настоящее время статистика это не только количество ударов и нарушений за матч, это еще и теплограммы активности игроков, набор индивидуальных действий каждого игрока, параметр ожидаемых голов и ключевые пасы [1]. Причем объем этой статистики достаточно велик, ведь за матч может произойти порядка 3000 событий [2].

Но обладать большим количеством данных – не значит раскрыть секрет победы, ведь нужно уметь их анализировать, правильно понимать их и уметь рассматривать их в правильном контексте. В то же время человеку порой трудно среди больших объёмов данных выделить наиболее существенные. А учитывая, что с каждым годом данных становится все больше, а статистика внедряется в спорт все больше – тот, кто научится понимать ее, откроет новую эпоху статистики в спорте. Причем важно отметить тот факт, что статистика захватила не только футбол. В настоящее время данные собираются и в других видах спорта: начиная от легкой атлетики и заканчивая баскетболом.

Можно смело утверждать, что объективный и грамотный анализ данных определит будущее множества спортивных дисциплин.

Но что, если для анализа данных в спорте можно использовать искусственный интеллект? Возможно, именно использование элементов математической статистики и искусственного интеллекта приведет спорт к новым открытиям. Ведь именно используя подобные технологии можно обработать те объемы данных, которые сейчас имеются в спорте. Возможности нейронных сетей заключаются не только в предсказании данных, с помощью них можно выявить наиболее важные критерии для достижения результатов.

В данный момент есть множество исследований, которые изучают спортивную статистику. В большей части работ делаются предсказания на основе уже прошедших событий, так, например, в работе [3] делается прогноз результатов олимпиады в 2014 году на основе результатов, показанных спортсменами. В некоторых исследованиях находят оптимальные параметры для того, чтобы достичь лучших результатов [4]. Также есть работы направлены на предсказывание результатов матчей [5-6].

В данном докладе для изучения возможности нейронных сетей в спорте был выбран бейсбол. Почему именно бейсбол? Все достаточно просто – именно в данном виде спорта был яркий пример использования данных и аналитики для достижения поставленной цели. История генерального менеджера “Окленда” Билли Бин и его ассистента Пола ДеПодесты поистине впечатляет. Стоит отметить, что уже на тот момент изучение статистики в бейсболе не стояло на месте. Билл Джеймс – бывший охранник консервной фабрики и журналист-любитель – к тому моменту уже опубликовал несколько занятных книг о бейсболе. Джеймс подвергал сомнению оценку игроков в 70-80-х годах прошлого века, по его исследованиям тренеры и руководители бейсбольных команд неправильно оценивают игроков и неверно учитывают статистические показатели. Он подверг сомнению самые базовые основы игры. И лишь спустя 20 лет труды Билла Джеймса были восприняты всерьез, именно Билли Бин смог разглядеть потенциал исследований, а в дальнейшем решил перевернуть игру с помощью статистики [7]. Их цель заключалась в выходе в плей-офф MLB. Основной проблемой был бюджет команды, “Окленд” на тот момент находилась в конце списка по финансовым ресурсам.

Именно ассистент Пол ДеПодест помог добиться успеха, он использовал статистику и показал, что для выхода в плей-офф нужно добиться как минимум 95 побед в сезоне [8]. Далее с помощью регрессионного анализа он доказал: чтобы добиться необходимого числа побед нужно совершить за сезон на 135 пробежек больше, чем команды противников [9]. Основываясь на этих данных ДеПодеста начал подбирать игроков. Что примечательно, для выбора игроков также использовалась статистика. Пол пытался воссоздать статистические показатели лидеров лиги с помощью целого ряда игроков с какими-либо недостатками вроде травм

или проблем с дисциплиной (они стоили значительно меньше, чем средние игроки или звезды лиги).

Пол ДеПодеста и Билл Джеймс изменили бейсбол. И их успехи не остались незамеченными: многие команды главной лиги бейсбола, включая великих «Янкиз», изменили свой подход к анализу и обработки данных. А в 2003 году Майкл Льюис опубликовал книгу о статистической революции генерального менеджера Бина и ассистента ДеПодесты под названием Moneyball [13], и книга эта тут же стала бестселлером. А через семь с половиной лет ее экранизировали, в фильме снимались Беннетт Миллер, Брэд Питт, Джона Хилл и другие голливудские звезды.

В данной работе преследуется аналогичная цель, что и у Билла Бина и его ассистента Пола ДеПодесты – по данным показателям команды за регулярный сезон необходимо определить, пройдет она в плей-офф или нет.

Для прогноза были выбраны следующие 11 критериев:

- (League) – лига, в которой выступала команда
- (Year) – год, в котором был получен данный результат
- (RS) – совершенных пробежек
- (RA) – пропущенных пробежек
- (W) – побед в сезоне
- (OBP) – процент попадания на базы
- (SLG) – процент результативных отбиваний
- (BA) – средний коэффициент результативности отбивания
- (G) – количество игр за сезон
- (OOBP) – процент попадания на базу противником
- (OSLG) – процент результативности отбивания противником

Именно эти критерии использовали Пола ДеПодесты и Билла Бин для анализа (на этот набор данных ссылаются в курсе «The Analytics Edge» на EdX во время лекции, посвященной истории Moneyball).

Необходимо предсказать, пройдет команда в плей-офф или нет (бинарная классификация).

Для проектирования искусственной нейронной сети была использована программа «Нейросимулятор 5», которая способна показать хорошие результаты даже на достаточно маленькой выборке. В качестве теоретической базы для построения модели использовались источники [10-12]. Были собраны данные о 420 результатах команд. Итоговое множество было поделено в соотношении 88:12, то есть 370 результатов для обучения нейросети и 50 данных для её тестирования.

После обучения нейронной сети средняя относительная погрешность составляла 4%, что является достойным результатом для полученной модели. На рисунке 1 представлены результаты тестирования.




Рисунок 1. Результат тестирования нейронной сети (выход команды в плей-офф)

На рисунке 2 представлена гистограмма, показывающая распределение значимости параметров. Самым значимым параметром оказалось количество побед, это объясняется тем, что чем больше побед, тем больше очков – а значит больше шансов выйти в плей-офф. Данная гистограмма доказывает предположение Пола ДеПодесты.



Рисунок 2. Значимость параметров (выход команды в плей-офф)

Теперь с помощью обученной модели можно определить – сколько побед достаточно для выхода в плей-офф. Для демонстрации была выбрана статистика команды “Окленд” в 2002 году (именно в этом сезоне происходили действия, описанные выше). Чтобы определить точное

количество побед необходимо варьировать искомым показателем, а остальные параметры зафиксировать.

Результаты анализа количества побед, необходимых для выхода в плей-офф представлены на рисунке 3. Можно заметить, что полученная оценка в 94 победы практически совпадает с оценкой в 95 побед, которая была получена Полом ДеПодесте в 2002 году [9]. Разница в 1 победу может быть обусловлена влиянием остальных параметров или неточностью в модели.




Рисунок 3. Количество побед необходимых для выхода в плей-офф

Последнее предположение, которое рассмотрено в данной работе – для выхода в плей-офф необходимо совершить за сезон на 135 пробежек больше, чем команды противников. Пробежки в бейсболе означают результативные действия, это аналог забитых мячей в футболе или заброшенных очков в баскетболе. Для решения поставленной задачи необходимо изменить данные модели. В качестве выходных данных было использовано количество побед, а показатели RS (совершенные пробежки) и RA (пропущенные пробежки) заменены на их разницу RD ($RD = RS - RA$).

Количества данных для обучения и тестирования остались неизменными по сравнению с первым обучением. Средняя квадратичная относительная ошибка тестирования составила 9,92%. На гистограмме, которая представлена на рисунке 4, представлено сравнение реального и полученного количества побед. Можно заметить, что результаты, полученные с помощью нейронной сети, достаточно правдоподобны.




Рисунок 4. Результат тестирования нейронной сети (количество побед)



Рисунок 5. Важность параметров (количество побед)

Отдельное внимание стоит уделить важности параметров в нейронной сети. На рисунке 5 представлена гистограмма, показывающая распределение значимости параметров для вычисления количества побед. Очевидно, что самым важным параметром является DR (разница между совершенными и пропущенными пробежками). Следующим шагом является вычисление необходимой разницы для достижения 95 побед, то есть попаданию в плей-офф.

Для вычисления необходимой разности пробежек будет использован метод, который был применен для вычисления количества побед. Результат представлен на рисунке 5. По рисунку видно, чтобы достичь 95 побед

необходимо, чтобы разница пробежек была равна 134. Результат практически совпадает с результатом, который был получен Полом ДеПодесте в 2002 году [9]. Для достижения 94 победы необходимо, чтобы разность была равна 121 пробежки.




Рисунок 5. Зависимость количества побед от разницы пробежек

Заключение. В результате проведенного исследования были построены две нейросетевых системы, которые делают прогноз, попадет ли команда в плей-офф и вычисляют количество побед в регулярном сезоне в зависимости от показателей. Все результаты оказались достаточно близки с теми, что получал спортивный менеджер Билли Бин и его ассистент Пол ДеПодеста. Стоит отметить тот факт, что они все-таки добились успеха и «Окленд» в 2002 году вышел в плей-офф Главной лиги бейсбола. В тот сезон команда выдала фантастическую серию из 20 побед подряд. При этом зарплатная ведомость «Окленда» составляла всего 44 миллиона долларов в год. На 81 миллион меньше, чем у лидеров «Янкиз»[7]. А значит, анализ статистики в спорте способен приносить результат.

Библиографический список

1. Сайт <https://www.barcamania.com/prodvinutaya-statistika-i-krasivaya-igra>
2. Сайт <https://marcetfootball.com/ru/futbol-i-statistika/>
3. Ясницкий Л.Н., Внукова О.В., Черепанов Ф. М. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта // Современные проблемы науки и образования. – 2014. – № 1; URL: <http://www.science-education.ru/115-11339> (дата обращения: 23.06.2020).
4. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд,

- готовящихся к участию в чемпионате Европы по футболу Евро-2016 методом нейросетевого моделирования // Вестник спортивной науки. 2015. № 5. С. 15-20.
5. Сайт <https://towardsdatascience.com/machine-learning-for-sports-betting-not-a-basic-classification-problem-b42ae4900782>
 6. Сайт <https://towardsdatascience.com/what-ive-learnt-predicting-soccer-matches-with-machine-learning-b3f8b445149d>
 7. Сайт <https://www.sports.ru/tribuna/blogs/vitalysuvorov/903982.html>
 8. Сайт <https://towardsdatascience.com/moneyball-linear-regression-76034259af5e>
 9. Сайт <https://www.samford.edu/sports-analytics/fans/2019/The-Moneyball-Science>
 10. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007.
 11. Ясницкий Л.Н. Интеллектуальные системы : учебник. – М.: Лаборатория знаний, 2016.
 12. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5.
 13. Michael Lewis Moneyball : the art of winning an unfair game / New York : W.W. Norton, 2003.

FORECASTING RESULTS OF SPORTS EVENTS BY MEANS OF NEURAL NETWORKS

Chelpanov Vasiliy A.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

The article describes the development of a neural network system for predicting the results of teams in Major League Baseball (MLB). The system allows you to predict whether the team will reach the playoffs according to the results that were shown during the regular season. Several studies have been carried out that are aimed at studying the use of neural systems in sports.

Key words: sports, baseball, sports analytics, statistics, neural network, forecast.

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ СТОИМОСТИ БРИЛЛИАНТОВ

Беляков Кирилл Викторович

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15
kiribel2000@gmail.com

В статье представлено описание разработки нейросетевой системы для оценки стоимости различных бриллиантов. Система позволяет совершить оценку стоимости бриллианта по его физическим характеристикам, а также внешним качествам. Был проведён ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: бриллиант, алмаз, драгоценные камни, оценка стоимости, самоадаптация, модель, нейронная сеть, прогноз.

Введение. Может показаться, что узнать стоимость бриллианта довольно просто. Нужно умножить цену за единицу массы на вес. Однако это является очень грубой оценкой. Бриллиант может оказаться с большим количеством дефектов, что сильно снизит его цену, или настолько хорошо ограненным, что цена может существенно увеличиться. В связи с этим при оценке стоимости камня нужно учитывать не только вес, но и его внешние характеристики, такие как: размеры, прозрачность, цвет и качество огранки.

Для того, чтобы узнать приблизительную стоимость необходимо обращаться к специальным таблицам и калькуляторам [4-6]. Естественно, большинство из них сильно ограничены, и не охватывают все параметры ювелирного изделия.

Для того чтобы определить влияние дополнительных характеристик на стоимость бриллианта, имеет смысл построить математическую модель на основе нейронной сети.

В результате анализа были выбраны следующие параметры: X1 – Масса (в каратах), Качество обработки (Fair, Good, Very Good, Premium, Ideal), Цвет (D, E, F, G, H, I, J), Прозрачность (I1, SI2, SI1, VS2, VS1, VVS2, VVS1, IF), Длина (мм), Ширина (мм), Глубина (мм). Выходной параметр: D1 – Стоимость (длр.).

Таблица 1. Кодировка качества обработки

Качество обработки	Код
Fair	1
Good	2
Very Good	3
Premium	4
Ideal	5

Таблица 2. Кодировка цвета

Цвет (от цветных к бесцветным)	Код
J	1
I	2
H	3
G	4
F	5
E	6
D	7

Таблица 3. Кодировка прозрачности

Степень прозрачности (от дефектных к прозрачным)	Код
II	1
SI2	2
SI1	3
VS2	4
VS1	5
VVS2	6
VVS1	7
IF	8

Итоговое множество для нейросети содержит данные о характеристиках и стоимости бриллиантов. Само множество было скачано с сайта [kaggle.com](https://www.kaggle.com) [7].

Для создания и тестирования нейронной сети была использована программа «Нейросимулятор 5» [1]. Для корректного построения сети были изучены специальные материалы [2]. Также была изучена аналогичная этой теме статья [3]. Итоговое множество включает в себя 53939 записей о бриллиантах. Оно было поделено в соотношении 94:6, то есть 50590 для обучения нейросети и 3349 для ее тестирования и подтверждающего множества (20 записей). Средняя квадратичная относительная ошибка тестирования составила 3,94%.

Для того, чтобы удостовериться в корректности построенной модели, с ее помощью были вычислены стоимости бриллиантов из подтверждающего множества, которое не участвовало в обучении и тестировании.

Рисунок 1 демонстрирует гистограмму, отображающую разницу между исходными значениями выходного параметра и значениями, полученными нейронной сетью. Из нее следует, что нейросеть корректно обучилась.




Рисунок 1. Результат тестирования нейронной сети

На рисунке 2 представлена гистограмма, показывающая распределение значимости параметров.

Как и ожидалось самым значимым параметром оказалась масса бриллианта. Однако на стоимость существенно повлияла и длина с глубиной. Оказавшими минимальное влияние стали следующие параметры: качество обработки и ширина бриллианта. Так как множество состоит из бриллиантов круглой огранки, то длина приблизительно равна ширине, что и повлияло на оценку этого параметра как неэффективного, ведь он просто дублирует другой параметр.

Таким образом, была спроектирована нейросеть, предназначенная для оценки стоимости бриллиантов.




Рисунок 2. Значимость параметров

Далее было выполнено исследование трех бриллиантов, посредством увеличения значения одного из параметров и фиксирования всех остальных. С помощью этого метода можно понять, как именно исследуемый параметр влияет на значение выходного параметра. Для исследования были выбраны бриллианты из трех разных ценовых категорий (дешевый, средней цены, дорогой). Характеристики бриллиантов приведены в таблице 1.

Таблица 4 – Характеристики бриллиантов

	Дешевый	Средней цены	Дорогой
Вес	0.21 крт	1.01 крт	2.14 крт
Качество обработки	4	4	4
Цвет	2	2	6
Прозрачность	3	2	4
Длина	3.89 мм	6.51 мм	8.39 мм
Ширина	3.84 мм	6.49 мм	8.43 мм
Глубина	2.31 мм	3.86 мм	5.00 мм
Стоимость	326 \$	3928 \$	15418 \$

В рамках этой статьи рассматривается то, как характеристики качества бриллианта влияют на его стоимость в разных ценовых категориях.

При помощи, построенной нейросети была оценена стоимость выбранных бриллиантов (рисунок 3).




Рисунок 3. Результаты оценки стоимости бриллиантов

На рисунках 4, 5, 6 показана зависимость стоимости бриллианта от его внешних характеристик. Полученный результат еще раз доказывает значимость прозрачности бриллианта при его оценке, так как максимальная стоимость при наилучшей прозрачности намного больше, чем при максимальных значениях других параметров.

На всех рисунках заметно, что стоимость увеличивается сильнее если бриллиант был дороже.

При более подробном рассмотрении данных о цвете и прозрачности было замечено, что если бриллиант находится в низкой ценовой категории и имеет плохое качество, то при увеличении соответствующего параметра, его стоимость увеличивается не сразу, а приблизительно с середины графика. Если же взглянуть на другие ценовые категории, то ситуация оказывается обратной. Существенное изменение стоимости происходит только при низком качестве изделия, а изделия высокого качества имеют не такую высокую разницу в цене.

Это обусловлено тем, что рынок переполнен камнями низкой ценовой категории и плохого качества, поэтому при небольшом увеличении качества такая маленькая разница в цене. Более "чистых" камней намного меньше, из-за чего стоимость при высоком качестве увеличивается сильнее. Также в более мелких камнях изъяны заметны намного меньше, чем в больших.

Камни же высокой ценовой категории намного больше и их недостатки намного заметней, из-за чего большие бриллианты плохого качества так низко и оцениваются по сравнению с бриллиантами высокого.

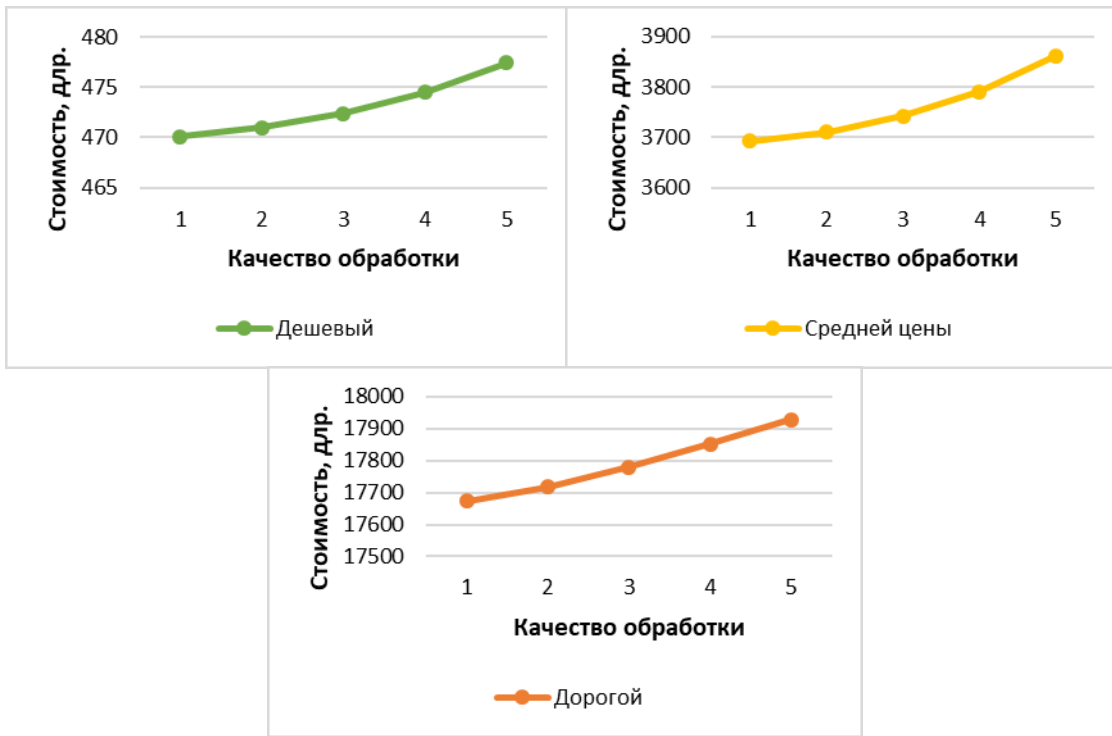


Рисунок 4. Зависимость стоимости бриллианта от качества обработки

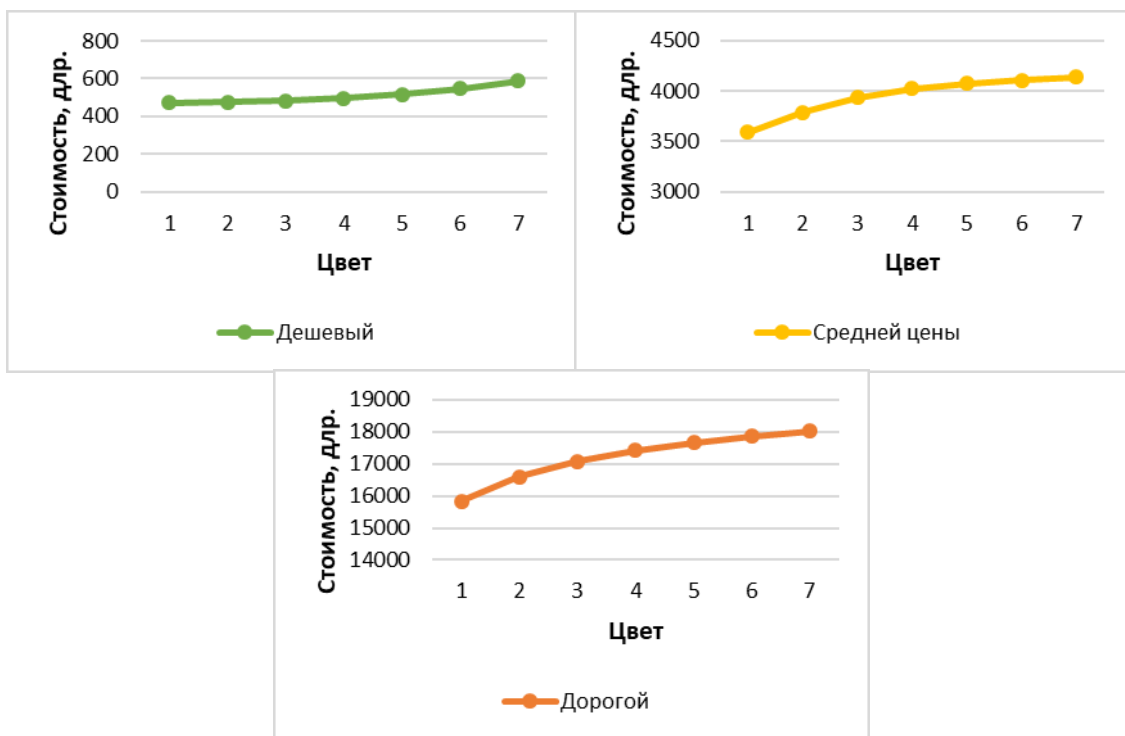


Рисунок 5. Зависимость стоимости бриллианта от цвета

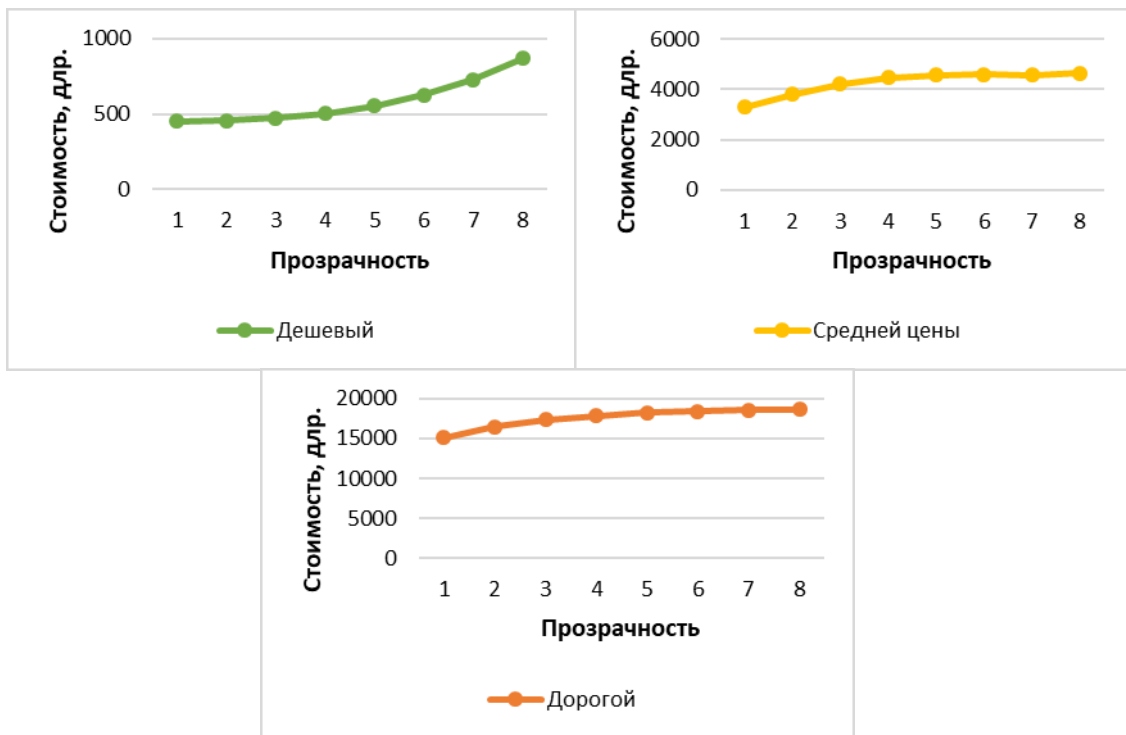


Рисунок 6. Зависимость стоимости бриллианта от прозрачности

Также существенным показателем влияния качества на стоимость является, то, насколько дороже идеальный бриллиант (все показатели качества являются максимальными), чем бриллиант низкого качества (все показатели качества являются минимальными) при одинаковой форме и весе. Эти данные отображены на рисунке 7. Заметно, что идеальный камень в несколько раз дороже, чем камень очень низкого качества.




Рисунок 7. Отличие стоимости камней кардинально разного качества

Здесь хотелось бы обозначить отличия текущей работы от упомянутой выше статьи [3]. В описанной там нейросети присутствуют еще два входных параметра: "размер площадки" и "отношение двойной глубины бриллианта к ширине и длине". В данном исследовании эти параметры были исключены, так как они зависят от других выбранных параметров: длины, ширины и глубины. Также в статье [3] самым значимым параметром являлась глубина бриллианта, а его вес не имел значимости, что диаметрально противоположно описанному в этой статье. Скорее всего это связано с различными исходными множествами.

Сама же работа [3] больше направлена на исследование зависимости стоимости бриллианта от его размеров (длины, ширины, глубины), в то время как данная описывает зависимости от визуальных качеств (цвет, качество огранки, прозрачность).

Также в отличии от предыдущей статьи [3], происходит исследование бриллиантов трех разных ценовых категорий, вместо одного, что значительно влияет на результаты.

Заключение. Построена нейросетевая система, предназначенная для оценки стоимости бриллиантов разного качества. На основании представленной модели было проведено исследование на предмет выявления визуальных свойств, существенно влияющих на итоговую стоимость. Проведены исследования трех случайно взятых бриллиантов из разных ценовых категорий. Модель может применяться во время купли-продажи драгоценных камней, для более простого определения стоимости.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
2. Ясницкий Л.Н. Интеллектуальные системы : учебник. – М.: Лаборатория знаний, 2016. – 221с.
3. Симонова Н.А. Нейросетевая система оценки стоимости бриллиантов // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Третьей всероссийской научно-практической конференции (г. Пермь, 14–18 мая 2018 г.) / Пермский государственный национальный исследовательский университет – Пермь, 2018. – С. 46-52.
4. Сайт <https://www.diamanters.ru>
5. Сайт <https://www.brilliant24.ru>
6. Сайт <https://www.diams.ru>
7. Сайт <https://www.kaggle.com/shivam2503/diamonds>.

NEURAL NETWORK SYSTEM FOR EVALUATING THE VALUE OF DIAMONDS

Belyakov Kirill V.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, kiribel2000@gmail.com

The article provides a description the development of a neural network system for evaluating the cost of various diamonds. The system allows you to evaluate of the value of a diamond based on its physical characteristics, as well as external qualities. A number of studies have been conducted, the results of which are presented in this article.

Key words: diamond, precious stones, cost estimation, model, neural network, forecast.

УДК 159.9.075

ПРОГНОЗИРОВАНИЕ СУИЦИДАЛЬНОГО ПОВЕДЕНИЯ

Алдарова Динара Андреевна

Пермский государственный национальный исследовательский университет,
КМБ, 614990, Россия, г. Пермь, ул. Букирева, 15, dinara_aldarova@psu.ru

В работе представлено описание разработки и применения нейросетевой модели для выявления людей, потенциально способных совершить суицид. Были определены наиболее влияющие параметры. Выявлено, что главным образом суицид совершается на фоне психических заболеваний. Проведено моделирование для отдельных людей, совершивших или не совершивших суицид, позволяющее определить, какие обстоятельства могли изменить их решение. Работа будет полезна в психологии для предотвращения возможных суицидов в разных слоях населения.

Ключевые слова: суицид, прогнозирование, нейронная сеть, нейросимулятор.

Суицид – это намеренное лишение себя жизни любым возможным способом. За исключением стран, где разрешена эвтаназия для тяжело больных, для людей это единственный способ расстаться с жизнью.

Согласно данным ВОЗ за 2012, 2015 и 2016 года Россия стабильно находится на третьем месте среди 183 исследованных стран мира по числу самоубийств на 100 тысяч населения.

К суициду людей может подталкивать множество факторов от психических заболеваний до экономической обстановки в стране. Попробуем

разобраться, насколько сильно они влияют на решение о самоубийстве, обучив нейронную сеть выборкой из реальных данных.

Для прогнозирования выбрана исходная информация, которую легче всего найти о человеке: возраст, пол, семейное положение, наличие психических расстройств или тяжелых болезней, алкогольной и/или наркотической зависимости. Также для каждого человека из выборки определено, был ли он самоубийцей. Информация обезличена, то есть помимо указанных показателей не содержится никакой дополнительной личной информации. Всего 372 записи, собранные из различных источников: новостные ресурсы, исторические хроники.

Для создания и обучения нейронной сети применяется пакет «Нейросимулятор5» [2]. Основным источником, раскрывающим теоретические основы построения и применения нейронных сетей, являются учебные пособия [3,4].

Исходное множество данных разбито на обучающее и тестирующее, содержащие 332 и 40 записей соответственно. Оптимальная структура сети подобрана следующая: 7 нейронной на входном слое (указанные выше исходные данные в виде числовых значений), 1 нейрон на выходном слое (является ли человек самоубийцей), один скрытый слой с 2 нейронами. В качестве активационной функции используется тангенс гиперболический, за исключением выходного слоя: на нем используется линейная активационная функция. Для обучения используется механизм упругого распространения.

Первый этап работы с сетью после ее конфигурирования – это обучение, включающее в себя назначение случайных весов связям между нейронами и многократный прогон сети по наборам исходных данных из обучающего множества с коррекцией весов в случае получения неверного ответа. После каждой итерации обучения сеть также проверяется на тестовом множестве. При этом в случае неверного ответа веса не изменяются, т.к. тестовое множество позволяет определить текущую точность определения искомого параметра.

Итоговый вариант обученной сети был проверен на тестовом наборе данных. Результат проверки представлен на рисунке 1 в виде гистограммы, отражающей желаемые и полученные в процессе работы нейронной сети результаты.




Рисунок 1. Результаты проверки нейронной сети на тестирующем множестве

Следующим важным этапом исследования являлось выявление значимости параметров (рисунок 2).




Рисунок 2. Значимость параметров

Как видно из рисунка, наиболее важный параметр, влияющий на вероятность совершения суицида – это наличие психических расстройств. Пол и семейное положение человека влияют на результат наиболее слабо. Полученная модель позволяет не только определять вероятность совершения суицида для конкретной ситуации человека, но и промоделировать его поведение при изменении жизненных обстоятельств. Для этого возьмем входные параметры и будем изменять их, анализируя получаемую вероятность суицида.

Возьмем двух произвольных людей со следующими параметрами: мужчина 18 лет не в браке, без психических или физических заболеваний и без зависимостей, и женщина с аналогичными параметрами. Вычислим вероятность их суицида при изменении возраста или семейного положения.




Рисунок 3. Вероятность совершения суицида для людей без заболеваний и зависимостей

Для всех наборов входных параметров нейронная сеть показала один результат: 6,8%, что не превышает погрешности нейронной сети. Теперь добавим алкогольную и наркотическую зависимость.




Рисунок 4. Вероятность совершения суицида для людей с алкогольной зависимостью




Рисунок 5. Вероятность совершения суицида для людей с наркотической зависимостью




Рисунок 6. Вероятность совершения суицида для людей с алкогольной и наркотической зависимостью

Несмотря на то, что сам по себе параметр «семейное положение» имеет низкую значимость, при моделировании он оказывает сильное влияние на результат. Так, для людей в браке вероятность совершения суицида ниже, чем для одиноких людей. Также разная динамика наблюдается для мужчин и для женщин: мужчины совершают суицид чаще.




Рисунок 7. Вероятность совершения суицида для людей с тяжелым физическим заболеванием




Рисунок 8. Вероятность совершения суицида для людей с депрессией или психическими заболеваниями

В результате моделирования вероятности суицида для людей с тяжелыми физическими или психическими заболеваниями стоит отметить влияние семейной жизни: люди с физическими заболеваниями, состоящие в браке, с меньшей вероятностью совершают суицид. В то же время для психических заболеваний картина иная: если для мужчин с возрастом вероятность уменьшается, то для женщин – увеличивается.

Таким образом, в процессе данной работы были выявлены следующие закономерности: в браке люди меньше подвержены суицидальному поведению. Для мужчин риск совершить суицид выше, чем для женщин в аналогичной ситуации. Тяжелые физические заболевания являются весомой причиной для суицида только для одиноких людей, для людей в браке

вероятность низкая. Алкогольная зависимость приводит к суициду в основном у одиноких людей. Наркотическая же зависимость приводит к суициду вне зависимости от семейного положения, особенно в молодом возрасте. Сочетание алкоголя и наркотиков резко повышает вероятность суицида. Основной же причиной совершения суицида являются депрессии или психические заболевания, даже при отсутствии других факторов и в любом возрасте. Именно на своевременном выявлении психических проблем у человека следует концентрироваться для уменьшения количества суицидов.

Библиографический список

1. Википедия: [Электронный ресурс] // URL: https://ru.wikipedia.org/wiki/Список_стран_по_количеству_самоубийств. (Дата обращения: 1.04.2020).
2. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
3. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – С.176.
4. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. С.221.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ ВЕРОЯТНОСТИ ВЫЖИВАНИЯ ПАССАЖИРА НА БОРТУ ПАРОХОДА “ТИТАНИК”

Антонов Артем Алексеевич

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, artyom2800@yandex.ru

В статье представлено описание разработки нейросетевой системы для оценки вероятности выживания пассажира на борту парохода “Титаник”. В качестве входных параметров система получает набор характеристик пассажиров и делает на их основе оценку вероятности.

Ключевые слова: искусственный интеллект, нейросетевые технологии, оценка вероятности, пароход “Титаник”, безопасность, вероятность выживания.

Введение. В современной инженерии вопрос безопасности зачастую играет очень важную роль. В частности, такая задача стоит перед инженерами в области кораблестроения. Обеспечение безопасности пассажиров является нетривиальной задачей и требует глубокого анализа

данных прошедших лет. Данный анализ может быть улучшен с помощью применения искусственного интеллекта и нейросетевых систем.

Подход к проектированию безопасных систем на основе искусственного интеллекта имеет ряд преимуществ. При его использовании исключается человеческий фактор, что очень важно при работе над вопросом безопасности. Также нейросеть имеет способность к нахождению новых закономерностей, что не является легкой задачей для человека. В результате, зачастую, интеллектуальные системы, построенные на основе нейросетей, могут давать куда более точную оценку чем человек.

В данном исследовании предпринимается попытка использовать нейросетевые технологии для анализа данных на примере крушения парохода “Титаник” в 1912 году. Эффективность использования искусственного интеллекта в данной задаче была обоснована в работах зарубежных исследователей [1-2]. В качестве набора данных была взята информация о пассажирах на борту и их статусе после крушения. Информация о некоторых пассажирах из набора была удалена, поскольку для них отсутствовали значения некоторых параметров. Также, при подготовке данных несколько параметров были исключены, поскольку они не могут являться значимыми для данной задачи (например – имя пассажира). Таким образом, был выбран следующий окончательный набор параметров: X1 – класс билета, X2 – пол пассажира, X3 – возраст пассажира, X4 – количество родственников / супругов на корабле, X5 – количество родителей / детей на корабле, X6 – Стоимость билета, X7 – Порт отправки. Выходной параметр D1 – вероятность того, что пассажир выжил.

Некоторые параметры представлены в закодированном виде. Пол: 0 – женский, 1 – мужской. Порт отправки: 0 – Саутгемптон, 1 – Шербур, 2 – Куинстаун.

Набор входных данных был разбит на два множества в соотношении 80% и 20%. Более крупное множество использовалось для обучения нейросети, а меньшее для тестирования.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [3] по методике [4]. В результате работы были протестированы несколько моделей и была выбрана лучшая из них. Лучшая модель состоит из входного слоя с 7 нейронами, первого скрытого слоя с 16 нейронами, второго скрытого слоя с 8 нейронами и выходного слоя с 1 нейроном.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 143 примеров. Средняя относительная погрешность тестирования составила 22%. На рисунке 1 представлена гистограмма, демонстрирующая вероятность, которую предсказала нейросеть по сравнению с действительностью.



Рисунок 1. Результат тестирования нейронной сети

Из результатов, изображенных на рисунке 1, видно, что наиболее вероятный исход по мнению обученной модели в абсолютном большинстве случаев является верным. Если выбирать наиболее вероятный вариант, который предлагает нейронная сеть, то результат будет верным в 85,2% случаев.

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рисунке 2.




Рисунок 2. Значимость входных параметров нейросетевой модели

Исходя из данных, изображенных на рисунке 2, можно заметить, что наиболее влиятельными параметрами при оценке стали: класс билета, пол, возраст пассажира. Менее влиятельными стали: порт отправки, стоимость билета, количество родственников / супругов на корабле, количество

родителей / детей на корабле. Малую значимость порта отправки и стоимости билета можно объяснить тем, что они никак не влияли на способность пассажира спастись во время крушения, а класс билета, пол и возраст могли напрямую влиять на место нахождения на корабле и физические способности пассажира.

Также были рассчитаны коэффициенты корреляции Пирсона между входными параметрами модели и выходным. Результат расчета представлен на рисунке 3 в виде гистограммы.




Рисунок 3. Значения модулей коэффициентов корреляции Пирсона между входными параметрами и выходными

Из рисунка 3 можно заметить, что между возрастом и количеством родственников / супругов на корабле с выживаемостью нет линейной зависимости. Расчет значимости с помощью программы «Нейросимулятор 5», в отличие от методики Пирсона, позволил обнаружить влияние этих параметров на выживаемость пассажиров.

Далее было проведено исследование влияния параметров на результат. Исследование производилось с помощью метода «замораживания» [4], суть которого заключается в варьировании значения одного параметра и фиксации значений всех других параметров. Данный метод позволяет выявить влияние исследуемого параметра на выходной. Для этой цели были отобраны 5 пассажиров, информация о параметрах которых отражена в таблице 1.

Таблица 1 – Характеристики пассажиров, выбранных для исследования

Вх. параметр	Пассажир №1	Пассажир №2	Пассажир №3	Пассажир №4	Пассажир №5
X1	3	3	1	1	1
X2	1	0	1	1	0
X3	28.5	48	35	36	21
X4	0	1	0	1	2
X5	0	3	0	0	2
X6	16.1	34.375	512.3292	78.85	262.375
X7	0	0	1	0	1

На рисунке 4 показан график зависимости выживаемости от возраста. Как следует из графика, с увеличением возраста вероятность выживания имеет тенденцию к снижению. Однако также можно заметить, что это происходит нелинейно, так как для второго пассажира вероятность выживания возросла в итоге возросла.




Рисунок 4. Зависимость вероятности выживания от возраста

На рисунках 5-6 продемонстрирована зависимость вероятности выживания пассажира от количества родственников / супругов на пароходе и от количества родителей / детей на пароходе. В обоих случаях отсутствие общей тенденции, но при изменении количества родителей/детей на пароходе происходят гораздо более выраженные изменения.




Рисунок 5. Зависимость вероятности выживания от количества родственников / супругов на пароходе




Рисунок 6. Зависимость вероятности выживания от количества родителей / детей на пароходе

Напоследок, метод «замораживания» был применен к классу билета пассажира. На рисунке 7 изображен график зависимости вероятности выживания от класса билета. Как можно заметить, при увеличении данного параметра вероятность выживания пассажира падает во всех пяти случаях.

Из данного наблюдения можно сделать вывод о том, что каюты второго и третьего классов были гораздо менее приспособлены к эвакуации с судна.




Рисунок 6. Зависимость вероятности выживания от класса билета

Полученные результаты исследований не противоречат реальности и в некоторых случаях (класс билета) ей подтверждаются. Из этого следует, что спроектированную нейронную сеть можно считать пригодной для разбора причин катастроф, но не стоит всегда использовать ее как причину к действию, поскольку ошибка данной модели недостаточно для этого мала.

Заключение. Построена система нейросетевого оценивания вероятности выживания пассажира на борту парохода “Титаник”, которая может применяться для установления проблем безопасности людей на борту. Спроектированная нейросетевая модель учитывает семь параметров, которые включают в себя как и физические характеристики человека (возраст, пол) так и его характеристики как пассажира (класс билета, его стоимость и так далее). Методом сценарного прогнозирования построены графики зависимостей вероятности выживания от возраста, количества родственников / супругов, количества родителей / детей на пароходе и от класса билета. Выбранный набор входных параметров модели является легкодоступной информацией, в случае кораблекрушений, что позволяет использовать данную модель для анализа других катастроф, не только “Титаника”.

Библиографический список

1. Barhoom, Alaa M., et al. "Predicting Titanic Survivors using Artificial Neural Network." // International Journal of Academic Engineering Research. 2019. Vol. 3 Issue 9, Pages: 8-12.

2. Ekinici, E. Omurca, and N. Acun. "A comparative study on machine learning techniques using Titanic dataset." // 7th international conference on advanced technologies. 2018.
3. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
4. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

УДК 004.891.3

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЕШИФРАТОРА ЭЛЕКТРОМИОСИГНАЛА С ДАТЧИКОМ МЫШЕЧНОЙ НАГРУЗКИ

Трифонов Андрей Андреевич

Юго-Западный государственный университет,
305040, Россия, г. Курск, ул. 50 лет Октября, 94, SFilist@gmail.com

Представлена система управления экзоскелетом в биотехнической системе, предназначенной для восстановления двигательной активности мышц пациента. Сущность используемого метода управления экзоскелетом заключается в том, что при дешифрации электромиосигнала (ЭМС) используются не только ее амплитудные показатели, но и частотные характеристики. Для выделения релевантных областей ЭМС используется тензометрический датчик мышечной нагрузки.

Ключевые слова: электромиосигнал, экзоскелет, дешифратор электромиосигнала, нейронная сеть, агрегатор решений, алгоритм, биотехническая система, адаптация реабилитационной системы к пациенту.

Введение. На рынке медицинского оборудования присутствуют многочисленные реабилитационные экзоскелеты. Однако на сегодняшний день нет эффективных алгоритмов, обеспечивающих устойчивое перемещение пациента в экзоскелете в процессе вертикализации. Открытыми остаются и вопросы математического моделирования поведения пациента в экзоскелете. Основной претензией к медицинским экзоскелетам со стороны специалистов является отсутствие возможности их адаптации к конкретному пациенту, что требует контроля потенциальных физических возможностей пациента [1].

Для осуществления постинсультной реабилитации биотехническая система «экзоскелет – пациент» должна функционировать в комбинированном режиме. В определенный момент времени пациент занимает активное положение в системе и выполняет заданное движение самостоятельно. В другой момент времени пациент занимает в системе

пассивное положение и экзоскелет осуществляет заданное программно движение или движение, определяемое посредством декодирования электромиограммы (ЭМГ) пациента. В этом случае пациент совершает заданные движения с помощью экзоскелета, а биотехническая система определяет момент и размер необходимой помощи. Поэтому декодер электромиосигнала (ЭМС) должен определять не только тип движения и координаты конечности, но и усилие (момент), которое передается на соответствующий исполнительный орган экзоскелета.

Методы и модели. Известно множество технических решений, позволяющих управлять экзоскелетом посредством биотехнической обратной связи [3, 4, 8, 10, 11, 13]. Для управления процедурой реабилитации необходимы модули принятия решений для расшифровки поверхностных ЭМГ. Обученные классификаторы используются в качестве таких модулей для обеспечения принятия решений. Классификаторы построены на основе моделей нейронных сетей, моделей нечеткого вывода или гибридных (гетерогенных) моделей [2, 5, 6, 7, 12]. В то же время обучающие выборки для обучения этих классификаторов формируются из базы данных, полученной в результате поискового анализа по открытым базам данных физиологических сигналов.

Для разработки методов кодирования ЭМС мы анализируем процесс генерации этих сигналов. Сигнал ЭМС должен поступать в декодер, который решает включить или нет исполнительный механизм, соответствующий команде, зашифрованной в этом сигнале. Если рассматривать сервомотор в качестве исполнительного механизма, то командный декодер состоит из двух двухальтернативных классификаторов.

Амплитудные демодуляторы ЭМС были предложены в [13]. Для их реализации вводятся следующие показатели

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2},$$

(1)

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n|, \quad (2)$$

где N – ширина окна ЭМС, в котором вычисляется RMS или MAV , x_n – значения отсчетов ЭМС в этом окне.

Модель декодера определяется моделью кодера. Если декодер основан на модели нейронной сети (NET), то количество входов NET определяется шириной окна N , шагом его перемещения вдоль сигнала ЭМС и частотой его дискретизации. В свою очередь выбор N определяется продолжительностью возбуждения двигательных единиц (ДЕ) работающей мышцы. При условии, что частота дискретизации ЭМС выбрана равной 500 Гц, мы получаем 25 выборок в интервале ширины окна.

Основным недостатком формирования ИП согласно (1) и (2) является то, что в окне используются только амплитудные характеристики отсчетов

сигнала, а на декодер ЭМГ поступают «окна» независимо от степени активности мышц. Это приводит к снижению информативности ЭМС и достаточно высокому уровню ошибок в классификации команд. Поэтому повышение точности классификации команд осуществляется за счет дублирования ЭМС по нескольким каналам в момент двигательной активности и расшифровки сформированного таким образом вектора ИП посредством использования обучаемой нейронной сети.

Сущность предлагаемого метода управления экзоскелетом состоит в том, что при дешифрации ЭМС используются не только их амплитудные показатели, но и частотные характеристики. Причина – известно, что повышение двигательной активности приводит не только к росту амплитуды ЭМС, но и к увеличению числа задействованных ДЕ. То есть для кодирования ЭМС используется гипотеза об амплитудной и частотной модуляции этого сигнала [9]. Соответствующий демодулятор используется для построения кодера. Его выходные сигналы используются в качестве ИП для соответствующих декодеров.

Так же, как и в известных методах, с целью адаптации функционального состояния пациента и процесса вертикализации, в дешифраторе используются множество дублирующих каналов ЭМС, связанных с мышцей или группами мышц, контролирующими движение одного и того же сустава в конечности. В результате на выходе классификатора каждого канала получаем число, соответствующее уверенности в команде управления серводвигателя экзоскелета. Для агрегации решений по каналам классификаторов все их выходы поступают на нечеткую нейронную сеть. Ее дефазификатор формирует управляющий сигнал на контроллер серводвигателя. В результате анализа этого сигнала контроллер определяет скорость и направление вращения серводвигателя.

Сущность метода управления экзоскелетом заключается в сегментации текущего сигнала ЭМС на не пересекающиеся окна шириной TW с последующим формированием из отсчетов каждого окна информативного признака FD . С этой целью осуществляют переход от текущего дискретного отсчета ЭМС x_τ к отсчету y_τ , получаемому путем сравнения текущего отсчета с порогом Θ и вычисляемому согласно выражению

$$y_\tau = \begin{cases} 1, & \text{если } |x_\tau| \geq \Theta; \\ 0, & \text{если } |x_\tau| < \Theta. \end{cases} \quad (3)$$

На основе отсчетов (1) вычисляют информативный признак в окне TW как


$$FD = \frac{1}{TW} \sum_1^{TW} y_\tau. \quad (4)$$

На рисунке 1 показано, как из сигнала ЭМС $x(t)$ на рисунке 1а получается сигнал $y(t)$ по рисунку 1б для одного порога Θ_i . На ширине окна

можно использовать множество порогов Θ и, как следствие, получить множество информативных признаков FD . Таким образом, на апертуре окна TW формируется множество информативных признаков (3), на основе распознавания которых на серводвигатели подаются соответствующие команды. Задавшись апертурой ЭМС, на которой принимается решение о включении серводвигателя, можем выделить на ней множество окон. Учитывая, что временная апертура дешифрации ЭМС составляет 250 мс, а минимальный информационный квант, то есть минимальный отрезок ЭМС, который переносит релевантную информацию, составляет 25 мс, агрегатор решений работает на апертуре 250 мс.



а)



б)

Рисунок 1. Иллюстрация перехода от сигнала ЭМС $x(t)$ (а) к сигналу $y(t)$ (б)

Рисунок 2 иллюстрирует процесс формирования окон. Так как решение, принимаемое по результатам анализа одного окна, является частным решением, то необходим агрегатор этих решений.




Рисунок 2. Иллюстрация процесса формирования окон на апертуре ЭМС

Таким образом, приходим к выводу, что необходимы две ступени дешифрации ЭМГ. Для осуществления дешифрации ЭМС на двух ступенях используем обучаемые нейронные сети прямого распространения сигнала. Первая нейронная сеть (*NET1*) работает с пространством информативных признаков (2), сформированном в окне T_w . В качестве агрегатора также используем обучаемую нейронную сеть прямого распространения, которая работает на апертуре $MW = \text{int}(250/W)$ или, если используются окна с перекрытием, то на апертуре $MW = \text{int}((250 - T_w)/W)$, где W – шаг перемещения окна на апертуре ЭМС.

Для синхронизации работы структурных элементов в дешифраторе ЭМС используется синхронизатор. Стробующие сигналы формируются синхронизатором и поступают на накопитель информативных признаков для *NET2*. Эти сигналы переключают регистры адреса блока памяти. Стробующий сигнал сигнализирует о том, что на выходах *NET2* появилась релевантная информация. После того, как выходами *NET1* будет сформирован вектор $\{NET1_j\}$, строб разрешает контроллеру серводвигателей исполнять команды, поступающие с *NET2*.

Результаты. Для управления серводвигателями экзоскелета в процессе вертикализации используем пять каналов ЭМГ, которые считывают ЭМС с большой ягодичной мышцы, двуглавой мышца бедра, полуперепончатой мышцы, полусухожильной мышцы, большой поясничной мышцы. Процесс вертикализации управляется посредством дешифрации ЭМС в каналах, а скорость вертикализации зависит от интенсивности этих сигналов. При определенных сочетаниях интенсивностей ЭМС в каналах серводвигатели могут остановиться в любой фазе процесса вертикализации. Для осуществления режима «сесть» используются каналы ЭМГ с подвздошно-поясничной мышцы. Для вертикализатора в дешифраторе ЭМС использовались шесть каналов ЭМГ и агрегатор дешифраторов канальных ЭМГ. Структурная схема такого дешифратора показана на рисунке 3.

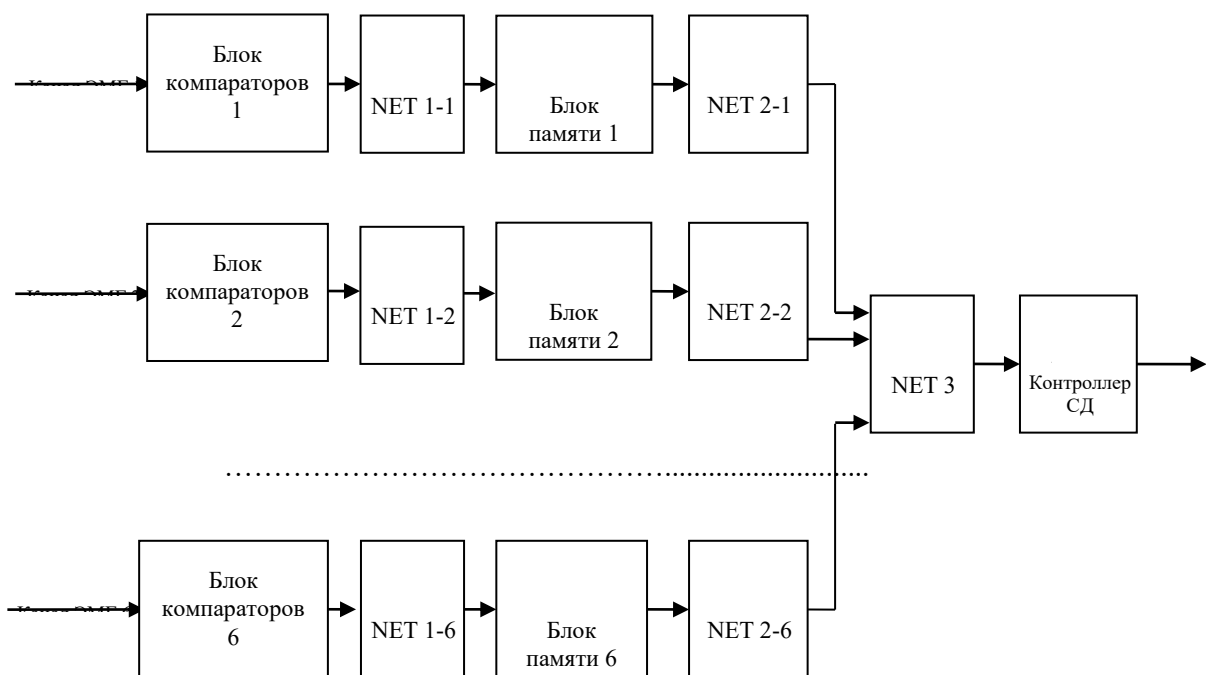


Рисунок 3. Структурная схема классификатора ЭМГ при использовании дублирующих каналов

В каждом канале включен блок компараторов, который осуществляет клиппирование ЭМС согласно (3) и вычисление информативного признака по клиппированному сигналу согласно (4). Нейронная сеть *NET1* в каждом канале получает на входе столько информативных признаков, сколько клиппированных сигналов выдает каналный компаратор. Блок памяти хранит решения *NET1* по каждому окну анализа, тем самым формируя входной вектор для *NET2*. Нейронная сеть *NET3* является нечеткой нейронной сетью и ее выход вычисляется путем дефаззификации шести функций принадлежности, фаззифицирующих выходы *NET2*.

На рисунке 4 показаны эпюры напряжений в одном из каналов ЭМГ и в канале тензометрического датчика, измеряющего величину мышечной нагрузки.




Рисунок 4. Эпюры напряжения в канале ЭМГ и в канале измерения мышечной нагрузки

Канал мышечной нагрузки позволяет организовать «временные ворота», через которые на дешифратор ЭМГ проходят только те «окна», в которых мышцами выполняется механическая работа.

Заключение. Для адаптивного управления экзоскелетом в процессе реабилитации использовался нейросетевой дешифратор ЭМС с дублирующими каналами и дополнительные каналы, контролирующие процесс выполнения механической работы, выполняемой мышцами пациента. Дешифратор ЭМС в каждом канале построен на основе двух последовательно включенных нейронных сетей и многопорогового компаратора ЭМС. Дешифрация ЭМС в каждом канале осуществлялась посредством пошаговой сегментации на пересекающиеся или на не пересекающиеся окна. Формирование вектора информативных признаков для нейронной сети первого уровня дешифрации осуществлялось посредством многопорогового компаратора, число порогов которого определяется размерностью вектора информативных признаков, а компоненты вектора информативных признаков определялись посредством процедуры клиппирования сигнала ЭМГ на различных уровнях компарации.

Вторая нейронная сеть предназначена для обобщения данных, получаемых при классификации векторов информативных признаков текущего окна. Размерность вектора информативных признаков для этой нейронной сети определяется числом окон ЭМС, используемых при принятии решения о включении/выключении соответствующего серводвигателя.

На основе базовой модели классификатора осуществлено управление движением экзоскелета в режиме «встать – сесть». Определено расположение электродов на группе мышц для осуществления режима вертикализации с комбинированным управлением. Полученные модели классификаторов поверхностных сигналов электромиограмм могут быть использованы при построении интеллектуальных систем реабилитации пациентов с неврологическими заболеваниями.

Благодарность. *Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 19-38-90112.*

Acknowledgments: The reported study was funded by RFBR, project number 19-38-90112.

Библиографический список

1. Аль-Баред, А.Я.С. Алгоритмы синтеза оптимального управления в биотехнических системах реабилитационного типа на основе технологий нейронных сетей/ А.Я.С. Аль-Баред, А.Н. Брежнева, Р.А. Томакова // Системный анализ и управление в биомедицинских системах. – 2018. – Т. 17, №3. – С. 750 – 754.
2. Белых В.С., Ефремов М.А., Филист С.А. Разработка и исследование метода и алгоритмов для интеллектуальных систем классификации сложноструктурируемых изображений // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2016. №2 (19). С. 12-24.

3. Бобе, А.С. Использование паттернов ЭМГ в задаче распознавания цикла ходьбы человека/ А.С. Бобе, Д.В. Конышев, С.А. Воротников// Прикаспийский журнал: управление и высокие технологии. 2016. № 3 (35). С. 21-28.
4. Будко Р.Ю., Старченко И.Б. Создание классификатора мимических движений на основе анализа электромиограммы // Труды СПИИРАН. 2016. Вып. 46. С. 76-89.
5. Метод классификации сложноструктурируемых изображений на основе самоорганизующихся нейросетевых структур / С.А. Филист, Р.А. Томакова, О.В. Шаталова, А.А. Кузьмин, К.Д. Али Кассим // Радиопромышленность. 2016. № 4. С. 57-65.
6. Модели нечетких нейронных сетей с трехстабильным выходом в инструментарии для психологических и физиологических исследований / С.А. Филист, Абдул Ра-хим Салем Халед, О.В. Шаталова, В.В. Руденко // Системный анализ и управление в биомедицинских системах. 2007. Т.6, №2. С. 475-479.
7. Нейросетевые модули с виртуальными потоками для классификации и прогнозирования функционального состояния сложных систем / А.В. Киселев, Т.В. Петрова, С.В. Дегтярев, А.Ф. Рыбочкин, С.А. Филист, О.В. Шаталова, В.Н. Мишустин // Известия Юго-Западного государственного университета. 2018. № 4 (79). С. 123-134.
8. Патент РФ RU 2 635 632 С1. Способ и система управления интеллектуальной бионической конечностью/Н.М. Иванюк, В.Р. Каримов, Р.Ю. Будко, П.В. Гронский, С.М. Клейман. Опубликовано 14.11.2017. Бюл. № 32.
9. Петрова, Т.В. Предикторы синхронности системных ритмов живых систем для классификаторов их функциональных состояний / Т.В. Петрова, С.А. Филист, С.В. Дегтярев, А.В. Киселев, О.В. Шаталова // Системный анализ и управление в биомедицинских системах. 2018. Т. 17. № 3. С. 693-700.
10. Трифонов, А.А. Биотехническая система с виртуальной реальностью в реабилитационных комплексах с искусственными обратными связями/А.А. Трифонов, Е.В. Петрунина, С.А. Филист, А.А. Кузьмин, В.В. Жилин //Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019; 9(4). – С.49-66.
11. Филист С.А. Кодовые образы сигналов электроэнцефалограммы для управления робототехническими устройствами посредством интерфейса мозг-компьютер/ С.А. Филист, Е.В. Петрунина, А.А. Трифонов, А.В. Серебровский//Моделирование, оптимизация и информационные технологии. Научный журнал, Том 7, № 1.- С.67-79.
12. Филист, С.А. Гибридная нейронная сеть с макрослоями для медицинских приложений / С.А. Филист, О.В. Шаталова, М.А. Ефремов // Нейрокомпьютеры. Разработка и применение. – 2014. – №6. – С. 35-39.

13. Ataee Pedram and Aleem Idris S. Patent US, 20150370333 A1, G 06 F 3/01. applicant: Thalmic Labs Inc. – Appl. No.: 14/737,081, Filed: Jun. 11, 2015, Pub. Date: Dec. 24, 2015, 27 p.

NEURAL NETWORK MODEL OF ELECTROMYOSIGNAL DECODER WITH MUSCLE LOAD SENSOR

Trifonov Andrey A.

Southwest State University

305040, Russia, Kursk, st. 50 years of October, 94, SFilist@gmail.com

The article presents an exoskeleton control system in a biotechnical system designed to restore the motor activity of the patient's muscles. The essence of the exoskeleton control method used is that when decoding an electromyosignal (EMS), not only its amplitude indicators are used, but also frequency characteristics. A strain gauge muscle load cell is used to highlight the relevant EMS areas.

Key words: electromyosignal, exoskeleton, decoder of electromyosignal, neural network, solution aggregator, algorithm, biotechnical system, adaptation of the rehabilitation system to the patient.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ УСПЕВАЕМОСТИ УЧЕНИКОВ

Субботин Игорь Вячеславович

Пермский государственный национальный исследовательский университет, ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15, theskeef79@gmail.com

В статье представлено описание разработки нейросетевой системы для предсказания оценок учеников средней школы. Система позволяет прогнозировать оценки учеников по их характеристикам и деятельности. Было проведено ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: ученики, учёба, школа, нейронная сеть, модель, оценка, предсказания, успеваемость.

Введение. Вы никогда не задумывались, как влияют различные характеристики человека на его успеваемость? Например, влияют ли романтические отношения? Или сколько часов в неделю нужно заниматься, чтобы получать наилучшие результаты? Цель данной работы – постараться ответить на изложенные выше и другие вопросы.

Данная тема является достаточно интересной для изучения и дальнейшего исследования. Если мы научимся прогнозировать успеваемость, используя характеристики и информацию о деятельности человека, то мы сможем давать рекомендации по улучшению успеваемости, начиная от самых банальных, заканчивая новыми, ранее не известными. Это возможно, потому что нейронная сеть обладает способностью нахождения новых закономерностей [4].

В данном исследовании предпринимается попытка использовать нейросетевые технологии для предсказания оценок учеников средней школы. Похожим исследованием уже занимались в работах [2],[3],[5], но использовались другие параметры для обучения. В качестве набора данных используются результаты опроса школьников из Португалии. Данные взяты с сайта [6]. Для прогнозирования оценок используются следующие параметры: X1 – пол(мужчина, женщина), X2 – возраст(годы), X3 – количество часов учебы в неделю (часы от 1 до 10), получается ли школьник стипендию (1 – получает, 0 – нет), X4 – посещает ли школьник дополнительные курсы (1 – посещает, 0 – нет), X5 – посещал ли школьник детский сад (1 – да, 0 – нет), X6 – находится ли школьник в отношениях (1 – да, 0 – нет), X7 – потребление алкоголя в неделю (число от 1 до 5, где 1 – практически не употребляет, 5 – употребляет очень много), X8 – состояние здоровья школьника (от 1 до 5, 1 – очень плохое, 5 – полностью здоров), количество пропусков (от 0 до 90), D1 – оценка (от 0 до 20).

Набор данных был разбит на тестовое множество и обучающее множество. Обучающее множество составляет 80% от всего набора данных, когда как тестовое остальные 20%. Деление на тестовое и тренировочное множество происходило случайным образом.

Для проектирования искусственной нейронной сети была использована программа «Нейросимулятор 5» [1]. Было протестировано несколько различных моделей, но в результате лучшей оказалась модель с 1 скрытым слоем с 16 нейронами. В качестве функции активации использовался гиперболический тангенс. Средняя квадратичная относительная ошибка тестирования составила 17,5 %. На рисунке 1 представлена гистограмма, демонстрирующая разницу между исходными значениями выходного параметра и прогнозируемого нейронной сетью.




Рисунок 1. Результат тестирования нейронной сети

Из результатов на рисунке 1 можно сделать вывод, что нейронная сеть часто предсказывает близкое значение, но не всегда.

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рисунке 2.




Рисунок 2. Значимость входных параметров нейросетевой модели

Из рисунка 2 видно, что наиболее значимыми оказались параметры: время учебы и возраст. Результаты соответствуют действительности. Время учёбы действительно влияет на оценку достаточно сильно, и, как будет показано далее, больше не всегда значит лучше.

Также были рассчитаны коэффициенты корреляции Пирсона между входными параметрами модели и выходным. Результат расчета представлен на рисунке 3 в виде гистограммы.




Рисунок 3. Значения модулей коэффициентов корреляции Пирсона между входными параметрами и стоимостью квартир

Сравнивая рисунки 2 и 3, можно заметить различия, например, между дополнительными курсами и полом практически нет линейной зависимости. Расчет значимости с помощью программы «Нейросимулятор 5», в отличие от методики Пирсона, позволил выявить влияние данных параметров на оценку ученика.

Далее было проведено исследование влияния параметров на оценку. Исследование производилось с помощью метода «замораживания» [7], суть которого заключается в варьировании значения одного параметра и фиксации значений всех других параметров. Данный метод позволяет выявить влияние исследуемого параметра на выходной. Для этой цели были отобраны 5 человек, информация о параметрах которых отражена в таблице 1.

Таблица 1 –Характеристики людей, выбранных для исследования

Параметры	Ученик № 1	Ученик № 2	Ученик № 3	Ученик № 4	Ученик № 5
X1	0	1	0	1	1
X2	15	15	16	17	17
X3	1	2	2	3	1
X4	0	1	0	0	0
X5	1	0	1	0	0
X6	1	1	1	0	1
X7	0	1	1	1	0
X8	1	4	1	1	4
X9	5	3	2	1	2

Параметры	Ученик №1	Ученик №2	Ученик №3	Ученик №4	Ученик №5
X10	6	6	2	2	2

На рисунке 4 показан график зависимости оценок учеников от возраста. Из графика видно, что в некоторых случаях с возрастом результаты ученика могут улучшаться и достигать некоторого максимума, но в целом, чем старше мы становимся, тем хуже работает наш мозг и тем меньше его способность к изучению нового и к адаптации.




Рисунок 4. Зависимость оценок учеников от возраста

На рисунке 5 представлена зависимость оценки от состояния здоровья ученика. Результаты, полученные на графике, выглядят достаточно интересно, так как в каких-то случаях при улучшении состояния здоровья человек начинает учиться лучше, а в каких-то хуже. В случае с состоянием здоровья тяжело дать однозначный ответ по улучшению успеваемости.




Рисунок 5. Зависимость оценок учеников от их состояния здоровья

На рисунке 6 представлена зависимость оценок учеников от количества учебного времени. На графике видно, что для каждого ученика есть некоторое оптимальное значение. В целом, общая тенденция для всех учеников отсутствует.




Рисунок 6. Зависимость оценок учеников от количества учебного времени

Далее, аналогичным методом, было проведено исследование влияния романтических отношений учеников на оценку.

На рисунке 7 изображена гистограмма, показывающая оценку ученика в отношениях и без них. Из гистограммы видно, что в большинстве случаев отношения плохо сказываются на успеваемости. Такой вывод не противоречит действительности, так как часто люди начинают больше времени тратить на вторую половинку и меньше на учебу. Но важно подчеркнуть, что в некоторых случаях бывает обратный эффект.




Рисунок 7. Зависимость оценок учеников от романтических отношений

Полученные результаты исследований в большинстве своем не противоречат реальности, но стоит заметить, что в некоторых случаях

результаты не соответствуют действительности. Для дальнейшего улучшения результатов необходимо собирать больше данных.

Заключение. Построена система нейросетевого оценивания успеваемости школьников. Спроектированная нейросетевая модель учитывает 10 параметров, влияющих на успеваемость ученика. Данные параметры включают в себя как физические характеристики человека (пол, возраст, здоровье), так и его жизненный распорядок (количество часов учебы, находится ли в отношениях и т.п.). Методом сценарного программирования построены графики зависимостей успеваемости ученика от возраста, состояния здоровья, количества учебного времени и романтических отношений. Выбранный набор параметров может быть расширен при помощи проведения опросов в различных школах и университетах.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
2. Ясницкий Л.Н., Кузнецов А.Г., Селезнева С.М., Солохина А.Д., Тюлькина Д.В., Черепанов Ф.М. Применение нейросетевых технологий в изучении акмеологического потенциала студентов вуза // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 4. С.120-126
3. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. – 101 – 105с.
4. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5. – С. 52.
5. Admasu Yekun, E., Teklay, «Student Performance Prediction with Optimum Multilabel Ensemble Model». (2019)
6. Сайт: <https://www.kaggle.com/uciml/student-alcohol-consumption>
7. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

DYNAMIC NEURAL NETWORK SYSTEM FOR PREDICTING STUDENT GRADES

Subbotin Igor V.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, theskeef79@gmail.com

The article describes the development of a dynamic neural network system for predicting student grades. The system allows people to evaluate student's grade based on different indicators.

Keywords: artificial intelligence, neural network technologies, education, self-adaptation, predictions, students.

ПРОГНОЗИРОВАНИЕ КОИНТЕГРАЦИИ ВРЕМЕННЫХ РЯДОВ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

*Файзуллин Ринат Васильевич, Поздеев Дмитрий Александрович,
Херинг Штефан, Чиченков Иван Иванович*

Ижевский государственный технический университет имени
М.Т.Калашникова,
426000, Россия, г. Ижевск, ул. Студенческая, 7, rf85@mail.ru

В статье рассмотрены коинтегрированные пары временных рядов, то есть такие пары, линейная комбинация которых образует стационарный процесс в смысле стабильности математического ожидания, дисперсии и автокорреляции первого порядка. Рассмотрена возможность использования модели рекуррентной нейронной сети с долговременной краткосрочной памятью Long Short-Term Memory (LSTM) для прогноза такой характеристики пар временных рядов, как коинтеграция. Исследование показало, что данная модель успешно справляется с поставленной задачей, а, следовательно, ее можно использовать для такого типа данных.

Ключевые слова: нейронная сеть, рекуррентная нейронная сеть (RNN), Long Short-Term Memory (LSTM), временной ряд, прогнозирования, коинтеграция.

Введение.

При прогнозировании состояния какого-то объекта, системы, мы сталкиваемся с временными рядами. Одним из направлений развития методов прогнозирования основан на поиске взаимозависимостей между временными рядами. В случае наличия линейной комбинации временных рядов, обладающих свойствами стационарного процесса, говорит о том что эти временные ряды коинтегрированы. Вопросы прогнозирования коинтегрированных временных рядов освещены в ряде источников как в общем виде [1, 2, 3], так и применительно непосредственно к экономическим [4, 5, 6] или техническим параметрам [7, 8, 9].

Теория определения коинтеграционных зависимостей.

Какие бы показатели мы не рассматривали (экономические, технические, биологические), процесс упреждения связан с поиском функциональных зависимостей временного ряда от времени или от других временных рядов или от собственных предыдущих значений. Последние называются авторегрессионными зависимостями:

$$\gamma_t = \phi\gamma_{t-1} + \varepsilon_t \quad (1)$$

Где случайная составляющая ε_t имеет нулевое математическое ожидание и стабильную дисперсию $\varepsilon_t \sim N(0, \sigma^2)$.

Стабильность математического ожидания, дисперсии и автокорреляции, является частым требованием при применении каких-либо методов. Большую популярность исследований временных рядов в целом и стационарности временных рядов в частности пришло из эконометрики, потому что многие экономические процессы нестационарны. В технике тоже часто встречаются временные ряды которую демонстрируют тенденции, достаточно регулярные циклы или другие проявления нестационарного поведения. Если какой-то из показателей стабильно растет во времени, то его можно привести к стационарному виду просто удалив линию тренда. Если это преобразование приводит к стационарному ряду, то он называется разностно-стационарным [10]. Это не единственный способ сделать ряд стационарным, но чаще всего можно от исходного ряда перейти к его первым разностям $\Delta Y_t = Y_t - Y_{t-1}$ и ряд станет стационарным.

$$\Delta Y_t = Y_t - Y_{t-1} = \varepsilon_t \quad (2)$$

Если для приведения к стационарному виду надо брать вторые разности, то процесс считается I(2) и так далее. В большинстве случаев достаточно первых разностей, вторые применяется заметно реже, а величина разностей выше 2 почти никогда.

Определив наше понимание стационарных временных рядов и приведения нестационарных временных рядов к стационарному виду, перейдем к описанию коинтеграции.

Если линейная комбинация I(1) временных рядов $Y_t = (y_{1t}, y_{2t} \dots y_{nt})^T$ обладает свойствами стационарного ряда, то их называют коинтегрированными.

$$\beta^T Y_t = \beta_1 y_{1t} + \beta_2 y_{2t} \dots + \beta_n y_{nt} \sim I(0) \quad (3)$$

Если существует хотя бы один такой вектор β , то набор данных считается коинтегрированными. Понятно, что если исходные ряды нестационарны, то чтобы их линейная комбинация была стационарной, то в нее должно входить минимум 2 временных ряда. Использование большого количество временных рядов в коинтеграционном соотношении осложнено взаимозависимостями между нестационарными временными рядами, что вызывает эффект мультиколлинеарности.

Понятно, что любой коинтеграционный вектор не уникален, потому что (4)

$$k \cdot \beta^T Y_t = (\beta^*)^T Y_t \sim I \quad (4)$$

Обычно коинтеграционное соотношение приводят к выражению зависимости одного временного ряда от других, тогда коинтеграционный вектор может быть записан, как (5)

$$\beta = (1, -\beta_2, \dots, \beta_n)^T \quad (5)$$

Таким образом коинтеграционное соотношение может быть представлено как

$$\beta^T Y_t = y_{1t} - \beta_2 y_{2t} - \dots - \beta_n y_{nt} \sim I(0) \quad (6)$$

или

$$y_{1t} = \beta_2 y_{2t} + \beta_3 y_{3t} + \dots + \beta_n y_{nt} + u_t \quad (7)$$

где $u_t = \beta^T Y_t \sim I(0)$

Получается, что мы предполагаем наличие некоего уравнения долгосрочного равновесия (8)

$$y_{1t} = \beta_2 y_{2t} + \beta_3 y_{3t} + \dots + \beta_n y_{nt} \quad (8)$$

Если для наличия коинтеграции необходимо чтобы комбинация временных рядов образовывала стационарный процесс, то при наличии нескольких временных рядов, то таких комбинаций может быть несколько, тогда говорят о наборе коинтеграционных векторов (9):

$$B^T Y_t = \begin{pmatrix} \beta_1^T Y_t \\ \vdots \\ \beta_r^T Y_t \end{pmatrix} = \begin{pmatrix} u_{1t} \\ \vdots \\ u_{rt} \end{pmatrix} \sim I \quad (9)$$

Один из результатов Грейнджера состоит в том, что в случае коинтегрированности I(1) рядов, модель зависимости временных рядов может быть представлена в форме модели коррекции ошибок (error-correction model – ECM) [11]. То есть существует некая функциональная зависимость (10)

$$\Delta y_{1t} = f(y_{1t-1} - (\beta_2 y_{2t-1} + \beta_3 y_{3t-1} + \dots + \beta_n y_{nt-1})) = f(u_{t-1}) \quad (10)$$

С одной стороны мы знаем что случайная составляющая u_t имеет нулевое математическое ожидание, а с другой что следующее изменение временного ряда зависит от значения случайной составляющей на предыдущем шаге. Таким образом, если процессы коинтегрированные, то они стремятся к значениям, которые заложены долгосрочным равновесием (8). Пользуясь этим можно следить за величиной случайной составляющей u_t и если ее анализ покажет что в какой-то момент это величина стала вести себя ни как стационарный процесс, то можно подозревать возникновение каких-то изменений в процессах, то есть фиксировать нарушение долгосрочного равновесия, то может означать в технике какую-то нештатную ситуацию, поломку, аварию, необходимость замены оборудования так далее.

Возникает необходимость тестирования временных рядов на стационарность и на коинтеграцию.

Модель прогнозирования коинтеграционных зависимостей на основе нейронных сетей.

Рекуррентные нейронные сети (RNN) являются мощными моделями прогнозирования, способные воспроизводить практически произвольную динамику [12]. В силу имеющихся ограничений при их обучении было выявлено, что стандартные RNN не могут обучаться при наличии временных задержек, превышающих 5-10 дискретных временных шагов между соответствующими входными и выходными сигналами.

Проблема исчезающих ошибок ставит под сомнение, действительно ли стандартные RNN могут демонстрировать значительные практические преимущества перед сетями прямой связи на основе временных окон.

Развитие идей рекуррентных нейронных сетей с учетом необходимости использования информации о более «старых» значениях временного ряда, привело к появлению модели рекуррентной нейронной сети с долговременной краткосрочной памятью Long Short-Term Memory (LSTM) [13]. LSTM может научиться преодолевать минимальные временные задержки, превышающие 1000 дискретных временных шагов, путем обеспечения постоянного потока ошибок через «карусели постоянных ошибок» (CEC) внутри специальных блоков, называемых ячейками. Модули мультипликативных ворот учатся открывать и закрывать доступ к ячейкам. Алгоритм решает сложные задачи с длительным запаздыванием, которые никогда не решались предыдущими алгоритмами RNN [13].

При исследовании возможностей LSTM было доказано, что модель не может научиться правильно обрабатывать определенные очень длинные или непрерывные временные ряды, которые априори не сегментированы на соответствующие обучающие подпоследовательности с четко определенными началом и концом [14].

Наличие коинтеграции является одним из свойств временного ряда и соответственно мы можем попытаться его прогнозировать. В ходе исследования было выбрано более 1000 коинтегрированных пар данных (дневные цены закрытия акции на бирже) и проверялась возможность спрогнозировать останутся ли пары коинтегрированными в будущем.

В ходе работы была реализована архитектура рекуррентной нейронной сети с долговременной краткосрочной памятью при помощи библиотеки PyTorch. Данная модель показала довольно хорошие результаты (86 ROC-AUC) и обошла по качеству все стандартные подходы прогнозирования. Разработанный алгоритм делает прогноз о сохранности коинтеграции пары на 10 дней вперед.




Рисунок 1. Изменения ошибки по мере обучения нейронной сети на тестовой и обучающей выборках)

Заключение. Проанализирована возможность использования модели рекуррентной нейронной сети с долговременной краткосрочной памятью Long Short-Term Memory (LSTM) для прогноза такой характеристики пар временных рядов, как коинтеграция. Исследование показало, что данная модель успешно справляется с поставленной задачей, а, следовательно, ее можно использовать для такого типа данных.

Библиографический список

1. Pfaff B. Analysis of integrated and cointegrated time series with R. – Springer Science & Business Media, 2008.
2. Granger C. W. J. Time series analysis, cointegration, and applications //American Economic Review. – 2004. – Т. 94. – №. 3. – С. 421-425.
3. Hargreaves C. Non-stationary time series analysis and cointegration. – Oxford University Press, 1994.
4. Kunst R. M., Franses P. H. The impact of seasonal constants on forecasting seasonally cointegrated time series //Journal of Forecasting. – 1998. – Т. 17. – №. 2. – С. 109-124.
5. Engle R., Granger C. Long-run economic relationships: Readings in cointegration. – Oxford University Press, 1991.
6. Bahmani-Oskooee M. Export growth and economic growth: An application of cointegration and error-correction modeling //The Journal of Developing Areas. – 1993. – Т. 27. – №. 4. – С. 535-542.
7. Shi H., Worden K., Cross E. J. A cointegration approach for heteroscedastic data based on a time series decomposition: an application to structural health monitoring //Mechanical Systems and Signal Processing. – 2019. – Т. 120. – С. 16-31.
8. de Souza Goncalves E., Rosa P. F. F. Sensor fusion with cointegration analysis for IMU in a simulated fixed-wing UAV //2017 International Conference on Military Technologies (ICMT). – IEEE, 2017. – С. 493-499.
9. Li W., Kong D., Wu J. A new hybrid model FPA-SVM considering cointegration for particular matter concentration forecasting: a case study of kunming and yuxi, China //Computational intelligence and neuroscience. – 2017. – Т. 2017.
10. Zivot E., Wang J. Modeling financial time series with S-Plus®. – Springer Science & Business Media, 2007. – Т. 191.
11. Granger C. W. J. Essays in econometrics: collected papers of Clive WJ Granger. – Cambridge University Press, 2001. – Т. 32. 523с.
12. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
13. Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8):1735 { 1780.
14. Gers F. A., Schmidhuber J., Cummins F. Learning to forget: Continual prediction with LSTM. – 1999.

FORECASTING THE CO-INTEGRATION OF TIME SERIES BASED ON NEURAL NETWORKS

Fayzullin Rinat V., Pozdeev Dmitry A., Hering Stefan, Chichenkov Ivan I.

Kalashnikov Izhevsk State Technical University,
426000, Russia, Izhevsk, st. Student, 7, rf85@mail.ru

The article discusses cointegrated pairs of time series, that is, such pairs, a linear combination of which forms a stationary process in the sense of the stability of the mathematical expectation, variance and autocorrelation. The possibility of using a recurrent neural network model with Long Short-Term Memory (LSTM) to predict such a characteristic of time series pairs as cointegration is considered. The research showed that this model successfully copes with the task, and, therefore, it can be used for this type of data.

Keywords: neural network, recurrent neural network (RNN), Long Short-Term Memory (LSTM), time series, forecasting, cointegration.

УДК 004.032.26

САМОАДАПТИРУЕМАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ МИРОВЫХ КАССОВЫХ СБОРОВ ФИЛЬМА

Зимин Илья Владимирович, Мироненко Анастасия Олеговна

Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15
ziminsrve@gmail.com, miss.mironenko@bk.ru

Агаев Шамиль

Тюменский государственный университет,
625003, Россия, г. Тюмень, ул. Ленина, 23
shamil.agaev1805@gmail.com

В статье представлено описание разработки нейросетевой системы для оценки мировых кассовых сборов фильма. Система позволяет прогнозировать объем мировых кассовых сборов фильма по характеристикам как самого фильма, так и режиссеров, актеров. Было проведено ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: кинематограф, кинобизнес, мировые кассовые сборы, финансы, kinopoisk, модель, нейронная сеть, прогноз.

Введение. В настоящее время, когда новые фильмы различных жанров и на всевозможные темы выходят в прокат ежедневно, согласно данным с

сайта kinopoisk, в день в среднем выходит около 3-х кинопремьер только в России, поэтому очень важно знать ответы на вопросы, типа: стоит ли вкладываться в кинобизнес? будет ли это приносить прибыль? какой жанр является наиболее выгодным? стоит ли делать фильм мультижанровым?

Любой режиссер перед съёмкой очередного, а может и первого в его карьере фильма, задаётся подобными вопросами. Поэтому тема кинобизнеса достаточно актуальна, а значит, есть смысл разработать экономико-математическую модель на основе нейронной сети, которая смогла бы помочь режиссерам.

На данный момент прогнозами кассовых сборов фильмов серьёзно занимается компания ООО «Метрополитэн Медиа». Еженедельно выходят статьи о прогнозе кассовых сборов в России от Андрея Белого в журнале «Бюллетень кинопрокатчика» на сайте [11].

А одними из первых исследователей, применивших в кинобизнесе метод экономико-математического моделирования, были Прэг и Касавант, которые в 1994 опубликовали статью [8] с сообщением о создании регрессионной модели на основе выборки из 625 американских фильмов. Рассматриваемый ими набор входных переменных включал производственный бюджет, критические обзоры, наличие звезд, наличие франшизы, наличие премий, жанр и рейтинг.

Аппарат нейронных сетей для прогнозирования кассовых сборов фильмов был впервые применен в 2002 году американскими учеными R.Sharda и D.Delen. В 2006 году эти же авторы [9] построили модели на основе логистической регрессии, дискриминантного анализа, классификационного и регрессионного дерева, а также нейронной сети, показавшей наилучший результат.

При разработке данной экономико-математической модели за основу были взяты статьи «Методика нейросетевого прогнозирования кассовых сборов кинофильмов» [5], «Экономико-математическая нейросетевая модель для оптимизации финансовых затрат в кинобизнесе» [6] и «Intelligent System for Prediction Box Office of the Film» [7].

Мы проанализировали работы [2-9], постарались учесть все, что не было учтено, сделали большой акцент на жанре фильма, а также на людях, которые каким-либо образом принимали участие в его создании. В результате анализа были выделены следующие параметры: X1 – Год выхода на экраны, X2 – Продолжительность фильма (минуты), X3 – Является ли фильм продолжением? (2-не известно, 1-да, 0-нет), X4 – Возрастное ограничение, X5 – Главная страна-производитель (1-Сьерра-Леоне 2-Сербия, ..., 218-Босния и Герцеговина), X6 – Причастие других стран (1-да, 0-нет), X7 – Наличие похожих фильмов (1-да, 0-нет), X8 – Среди жанров есть «мелодрама» (1-да, 0-нет), X9 – Среди жанров есть «комедия» (1-да, 0-нет), X10 – Среди жанров есть «аниме» (1-да, 0-нет), X11 – Среди жанров есть «военный» (1-да, 0-нет), X12 – Среди жанров есть «боевик» (1-да, 0-нет), X13 – Среди жанров есть «документальный» (1-да, 0-нет), X14 – Среди жанров есть «спорт» (1-да, 0-нет), X15 – Среди жанров есть «триллер» (1-да, 0-нет),

X16 – Среди жанров есть «криминал» (1-да, 0-нет), X17 – Среди жанров есть «мюзикл» (1-да, 0-нет), X18 – Среди жанров есть «драма» (1-да, 0-нет), X19 – Среди жанров есть «для взрослых» (1-да, 0-нет), X20 – Среди жанров есть «история» (1-да, 0-нет), X21 – Среди жанров есть «вестерн» (1-да, 0-нет), X22 – Среди жанров есть «приключения» (1-да, 0-нет), X23 – Среди жанров есть «фильм-нуар» (1-да, 0-нет), X24 – Среди жанров есть «концерт» (1-да, 0-нет), X25 – Среди жанров есть «короткометражка» (1-да, 0-нет), X26 – Среди жанров есть «ужас» (1-да, 0-нет), X27 – Среди жанров есть «мультфильм» (1-да, 0-нет), X28 – Среди жанров есть «фантастика» (1-да, 0-нет), X29 – Среди жанров есть «детектив» (1-да, 0-нет), X30 – Среди жанров есть «фэнтези» (1-да, 0-нет), X31 – Среди жанров есть «семейный» (1-да, 0-нет), X32 – Среди жанров есть «новости» (1-да, 0-нет), X33 – Среди жанров есть «музыка» (1-да, 0-нет), X34 – Наличие номинаций у актеров (1-да, 0-нет), X35 – Наличие номинаций у режиссёров (1-да, 0-нет), X36 – Общее количество актеров, X37 – Количество известных актеров, X38 – Общее количество режиссёров, X39 – Количество известных режиссёров, X40 – Количество актеров, X41 – Количество актрис, X42 – Наличие актеров нетрадиционной ориентации (1-да, 0-нет), X43 – Бюджет (млн. долл.). Выходной параметр: D1 – Мировые кассовые сборы (млн. долл.).

Итоговое множество для нейросети содержит данные по о фильмах разных стран и годов выпуска. Данные были собраны с сайта kinopoisk [10].

Для проектирования искусственной нейронной сети была использована программа «Нейросимулятор 5» [1]. Всего были собраны данные о 515690 фильмах (практически все фильмы, доступные на сайте [10]). Из них лишь 6828 содержали все необходимые данные для заполнения входных и выходных параметров. Итоговое множество было поделено в соотношении 95:5, то есть 6486 фильмов для обучения нейросети и 342 для ее тестирования. Средняя квадратичная относительная ошибка тестирования составила 4,02%, что можно назвать достойным результатом. На рисунке 1 представлена гистограмма, демонстрирующая разницу между исходными значениями выходного параметра и прогнозируемого нейронной сетью.




Рисунок 1. Результат тестирования нейронной сети

На рисунке 2 представлена гистограмма, показывающая распределение значимости параметров.

Самыми значимыми входными параметрами оказались: бюджет фильма, наличие актеров нетрадиционной ориентации в фильме, наличие номинаций у актеров, а также количество актеров/актрис. Абсолютно неэффективным оказался один параметр – год выхода на экраны, что еще раз подчеркивает сохранение актуальности системы.

Таким образом, была спроектирована самоадаптируемая к экономической ситуации нейросеть, предназначенная для оценки объема мировых кассовых сборов фильма.




Рисунок 2. Значимость параметров

Далее было выполнено исследование пяти случайно выбранных фильмов с сайта [10] за последние года (2017-2019). Исследование производилось с помощью метода «замораживания». Его суть – в изменении значения одного из параметров и фиксирования всех остальных. С его помощью можно понять, как именно исследуемый параметр влияет на значение выходного параметра. Выбор пал на следующие 5 фильмов: «Последний бросок», «Киборги», «Оно 2», «Первому игроку приготовиться», «1+1: Голливудская история». Основные характеристики фильмов приведены в таблице 1.

Таблица 1 – Основные характеристики фильмов

	Последний бросок	Киборги	Оно 2	Первому игроку приготовиться	1+1: Голливудская история
Год	2019	2017	2019	2018	2018
Продолжительность	103 минуты	110 минут	169 минут	140 минут	126 минут
Возрастное ограничение	18+	0+	18+	12+	16+
Является продолжением	Нет	Нет	Да	Нет	Да
Страна-производитель	США	Украина	Канада	США	США
Причастие других стран к созданию фильма	Нет	Нет	Да	Да	Нет
Наличие похожих фильмов на момент создания	Нет	Да	Да	Да	Да
Жанр	Боевик, триллер, криминал	Военный, драма, детектив	Ужасы, фэнтези, драма	Фантастика, боевик, приключения	Драма, комедия
Количество актеров	19	11	100	162	135
Наличие номинаций у актеров	Да	Нет	Да	Да	Да
Количество известных актеров	6	4	57	75	60

	Последний бросок	Киборги	Оно 2	Первому игроку приготовить	1+1: Голливудская история
Актеры нетрадиционной ориентации	Нет	Нет	Есть	Нет	Нет
Количество режиссеров	1	1	1	1	1
Количество известных режиссеров	1	1	1	1	1
Наличие номинаций у режиссеров	Нет	Нет	Да	Нет	Нет
Бюджет (млн. долл.)	2	1,7	79	175	37,5
Мировые кассовые сборы (млн. долл.)	0,003	0,885	473,1	582,9	125,9

Первые 3 фильма являются неудачными, так как бюджет гораздо превышает мировые кассовые сборы. В рамках данной статьи мы рассмотрим, что могли в свое время предпринять режиссеры фильмов «Последний бросок» и «Киборги», чтобы поднять мировые кассовые сборы.

При помощи построенной нейросети прогнозируем объем мировых кассовых сборов для 5 ранее выбранных фильмов. Результат представлен на рисунке 3. В 4-х случаях спрогнозированное значение оказалось больше реального.




Рисунок 3. Результаты оценки мировых кассовых сборов фильмов

На рисунках 4 показана зависимость мировых кассовых сборов от бюджета фильма. Исходя из полученных результатов можно сказать, что при увеличении бюджета, кассовые сборы фильма могут расти, не изменяться или убывать. В связи с этим, мы решили более подробно изучить зависимость объемов мировых кассовых сборов от бюджета и сделали это следующим образом: выбрали 100 случайных фильмов, оценили мировые кассовые сборы, после чего увеличили бюджет каждого фильма в 2 раза и оценили вновь, затем посчитали разницу (рисунок 5).

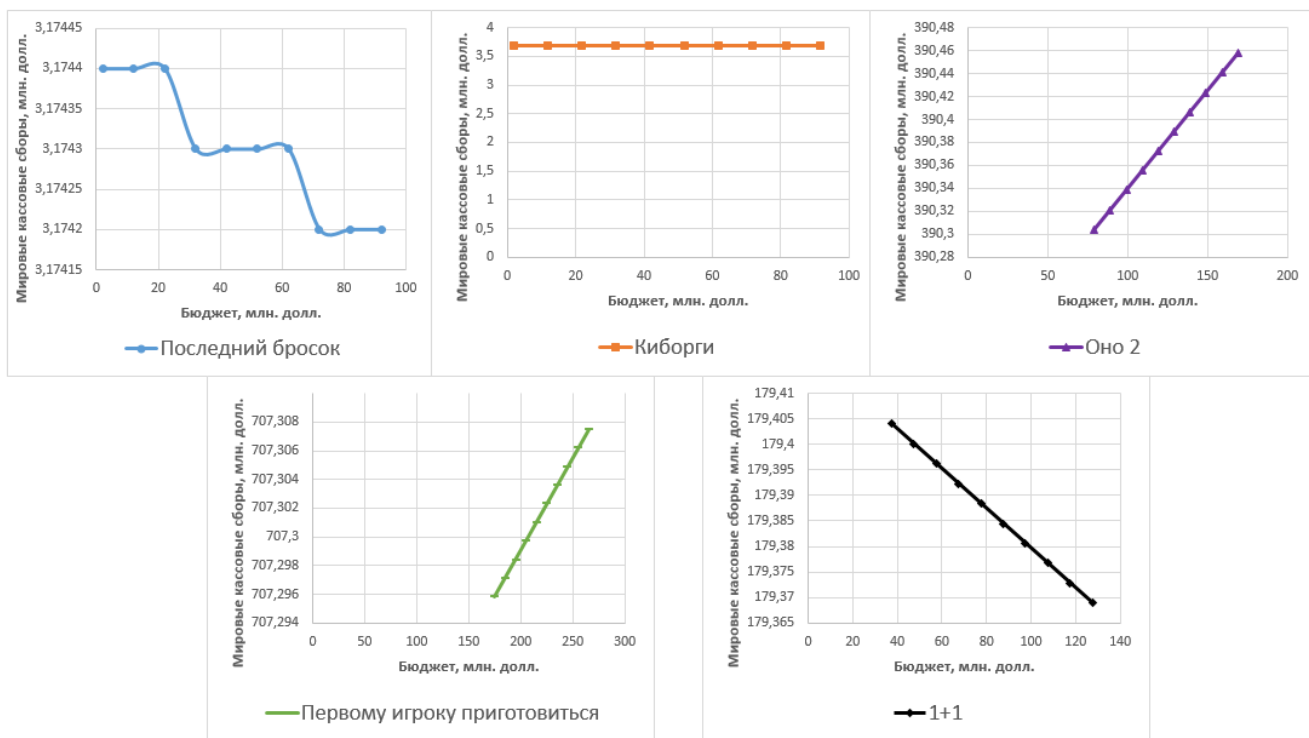


Рисунок 4. Зависимость мировых кассовых сборов от бюджета фильма



Рисунок 5. Разница в оценках при увеличении бюджета фильма в 2 раза

На рисунке 6 показана зависимость объем мировых кассовых сборов от наличия в фильме актеров нетрадиционной ориентации. В трех фильмах наличие таких актеров повлияло бы положительным образом и кассовые сборы увеличились, в остальных случаях присутствие таких актеров явно испортило бы фильм.




Рисунок 6. Зависимость объема мировых кассовых сборов от наличия в фильме актеров нетрадиционной ориентации

Далее аналогичным способом проведено исследование зависимостей мировых кассовых сборов фильма от количества актеров в фильме. На рисунке 7 видно, что объем мировых кассовых сборов может как убывать (у 2-х фильмов, так и расти).




Рисунок 7. Зависимость объема мировых кассовых сборов от общего количества актеров

Теперь проведем зависимость между наличием номинаций у актеров и объемом мировых кассовых сборов (рисунок 8). Из рисунка видно, что при наличии актеров с номинациями, объем сборов существенно больше.




Рисунок 8. Зависимость объема мировых кассовых сборов от наличия актеров с номинациями

Аналогичным образом проведем зависимость между наличием актеров с номинациями и объемом мировых кассовых сборов (рисунок 9). Если в предыдущем случае было все однозначно, и при наличии актеров с номинациями, кассовые сборы росли, то в этом случае у фильмов «Оно 2» и «1+1» резко упали.




Рисунок 9. Зависимость объема мировых кассовых сборов от наличия режиссеров с номинациями

Фильмы очень часто оцениваются по жанрам, поэтому важно оценить какой жанр является более предпочтительным. Всего на сайте [10] используется 26 жанров, мы выбрали по 100 фильмов каждого жанра (кроме жанров: концерт, для взрослых, новости, т.к. их в нашем множестве оказалось меньше 100) и посчитали средний объем мировых кассовых сборов. Из рисунка 9 видно, что самые прибыльные жанры – фантастика, мультфильм, фэнтези и семейный.




Рисунок 10. Средний объем мировых кассовых сборов по каждому жанру

Теперь, исходя из проведенных исследований, можно подобрать оптимальные значения каждого из параметров для фильмов «Последний бросок» и «Киборги», чтобы объемы их мировых кассовых сборов на порядок выросли и фильмы стали прибыльными.

Таким образом, если добавить в фильм «Последний бросок» добавить что-то из жанра «фэнтези», а в фильм «Киборги» из «фантастики», в оба фильма пригласить известных актеров с номинациями, поручить дело известному режиссеру и увеличить бюджет в 3 раза, то удастся поднять мировые кассовые сборы фильма «Последний бросок» до 59 млн. долл., а фильма «Киборги» аж до 300 млн. долл.

Конечно, если добавить в оба фильма что-либо мультипликационное, то объем мировых кассовых сборов еще поднимется, но это кардинально меняет сам фильм, поэтому такие изменения в данном случае не стоит применять.

Оптимальные основные параметры для фильмов «Последний бросок» и «Киборги» приведены в таблице 2.

Таблица 2 – Оптимальный набор основных параметров фильмов «Последний бросок» и «Киборги»

	Последний бросок	Киборги
Год	2019	2017
Продолжительность	103 минуты	110 минут
Возрастное ограничение	18+	0+
Является продолжением	Нет	Нет
Страна-производитель	США	Украина
Причастие других стран к созданию фильма	Нет	Нет
Наличие похожих фильмов на момент создания	Нет	Да
Жанр	Боевик, триллер, криминал, фэнтези	Военный, драма, детектив, фантастика
Количество актеров	19	11
Наличие номинаций у актеров	Да	Да
Количество известных актеров	6	4
Актеры нетрадиционной ориентации	Нет	Нет
Количество режиссеров	1	1
Количество известных режиссеров	1	1
Наличие номинаций у режиссеров	Да	Да
Бюджет (млн. долл.)	6	5,1

Заключение. Построена нейросетевая система, предназначенная для оценки мировых кассовых сборов фильма. В отличие от уже существующих, предложенная модель обучена на большом наборе фильмов и содержит большое количество параметров, которые раньше нигде точно не учитывались, например, тот же параметр «наличие актеров нетрадиционной ориентации». На основании представленной модели было проведено исследование на предмет выявления факторов, максимально влияющих на объем мировых кассовых сборов. Проведены исследования пяти случайно выбранных фильмов с сайта [10]. Модель может быть полезна в сфере кинематографа.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

2. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007. – 271 с.
3. Ясницкий Л.Н. Интеллектуальные системы : учебник. – М.: Лаборатория знаний, 2016. – 221с.
4. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5. – С. 48-56.
5. Ясницкий Л.Н., Белобородова Н.О., Медведева Е.Ю. Методика нейросетевого прогнозирования кассовых сборов кинофильмов // Финансовая аналитика: проблемы и решения. 2017. т. 10. Вып. 4. С. 449–463.
6. Ясницкий Л.Н., Плотников Д.И. Экономико-математическая нейросетевая модель для оптимизации финансовых затрат в кинобизнесе // Фундаментальные исследования. 2016. № 11 (часть 2). с. 339-342.
7. Intelligent System for Prediction Box Office of the Film // Integrated Science in Digital Age. – 2019. – Pp. 18-25.
8. Prag J. and Casavant J. An Empirical Study of the Determinants of Revenue and Marketing Expenditures in the Motion Picture Industry // Journal of Cultural Economics. – 1994. – No 18(3). – Pp. 217-235.
9. Sharda R., Delen D. Predicting box-office success of motion pictures with neural networks // Expert Systems with Applications. – 2006. – No 30. – Pp. 243-254.
10. Сайт <https://www.kinopoisk.ru>
11. Сайт <http://www.kinometro.ru/forecast>

SEMIADAPTIVE NEURAL NETWORK EVALUATION SYSTEM AND FORECASTING WORLD FILM CASH REGISTRATIONS

Zimin Ilya V, Mironenko Anastasia O.

Perm State University, Str. Bukireva, 15, Perm, Russia, 614990,
ziminsrve@gmail.com, miss.mironenko@bk.ru

Agaev Shamil

Tyumen state University,
23 Lenin street, Tyumen, 625003, Russia
shamil.agaev1805@gmail.com

The article provides a description of the development of a neural network system for evaluating the world box office grossing film. The system allows you to predict the volume of the world box office film on the characteristics of the film itself, as well as directors and actors. A number of studies have been conducted, the results of which are given in this article.

Keywords: cinema, film business, world box office, finance, cinema search, model, neural network, forecast.

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ МИРОВОГО РЕЙТИНГА ФИЛЬМА И ЗАВИСИМОСТЬ ЭТОГО РЕЙТИНГА ОТ ПОПУЛЯРНОСТИ КИНОЛЕНТЫ В СОЦИАЛЬНЫХ СЕТЯХ

Поселенцева Диана Юрьевна, Миков Роман Олегович

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, octopus.diana@gmail.com,
romasa37@gmail.com

Работа посвящена прогнозированию мирового рейтинга фильма на основе построения нейросетевой системы. Система позволяет прогнозировать мировой рейтинг фильма на основании одиннадцати входных параметров, таких как информация о режиссере, количество рецензий критиков о киноленте, длительность фильма, актеры главных ролей и т.д. Также система имеет возможность выявления тенденции изменения мирового рейтинга фильма в зависимости от входных параметров.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, мировой рейтинг киноленты, фильм.

Многие авторы сходятся на том, что основным критерием, определяющим успех фильма, является размер кассовых сборов, поскольку он объективно отражает финансовое преимущество, полученное в результате проката ленты [5, 6]. Однако в век информационных технологий, когда в Интернете аккумулируется, претерпевающая постоянные изменения и уточнения, различная информация, представляется возможным получить оценку популярности фильма, то есть его рейтинг, на основании мнения зрителей. Конечно, данная оценка, а именно рейтинг фильма, имеет субъективный характер, однако, в отличие от суммы сборов, она не зависит от различных экономических колебаний: инфляции, дефолта, роста и падение ВВП и т.д. Это позволяет использовать ее в качестве параметра оценки успешности фильма, а также помогает определить, насколько данная кинолента оказалась востребованной у публики. Поэтому задача прогнозирования рейтинга фильма на основе информации, доступной еще до его выхода, является достаточно актуальной в современных реалиях жизни.

Для решения поставленной задачи были применены нейросетевые технологии. Существует большое количество различных типов нейросетей: прямого распространения, сверточные, однослойные и многослойные перцептроны, и т.п. В данной работе был использован многослойный перцептрон.

При создании экономико-математической модели, предназначенной для прогнозирования рейтинга фильмов, в число входных параметров

нейронной сети были включены только те критерии, поиски которых не требуют большого количества времени и которые могут быть обработаны немедленно, без больших трудозатрат.

В качестве обучающего множества было использовано множество из 45 тыс. фильмов. Данный набор данных содержал в себе информацию следующего характера:

1. Данные о фильме: дата выхода, бюджет фильма, язык, компания и страна-производитель, рейтинг фильма с портала IMDb – крупнейшей в мире базе данных о кинематографе [1].

2. Ключевые слова (тэги) о сюжете.

3. Имена актеров, играющих в главных ролях.

4. Также были добавлены довольно специфические параметры – количество лайков на Facebook, одной из самых популярных социальных сетей в мире, как у режиссера, так и у самой киноленты и всей её съемочной группы. Данные параметры были введены для того, чтобы отследить их реальную значимость при выходе фильма в широкий прокат, ведь сейчас социальные сети оказывают достаточно сильное влияние на мнение человека.

Взятый для исследования набор данных изначально содержал в себе данные о более чем 45 тысячах фильмах, однако т.к. стоит задача прогнозирования рейтинга фильма, то необходимо убедиться в объективности оценок, которые были даны зрителями для конкретно взятых фильмов. Так была дана оценка тому, насколько много людей оценили каждый из представленных в массиве фильмов. Оказалось, что в используемом множестве данных достаточно большое количество фильмов, которые имеют низкое количество оценок. В результате произведенной фильтрации данных по количеству оценок были оставлены только те фильмы, которые имеют не менее 50-ти оценок кинолюбителей. Кроме того, исключены из обучающего множества были те фильмы, которые были выпущены до начала работы рейтингового сервиса IMDb, т.е. ранее 1990 года. Таким образом в результате предварительной фильтрации данных было выбрано около 4,5 тысяч фильмов, причем 5% из этих данных были выбраны в качестве тестового множества.

Как уже было отмечено ранее, для обучения была выбрана модель многослойного персептрона. Его структура приведена на рисунке 1.




Рисунок 1. Модель многослойного персептрона

У используемого персептрона 11 входных нейронов и 6 нейронов на скрытом слое. Данная модель, согласно множеству экспериментов, показала наилучшие результаты тестирования. Для прогнозирования использовался программный продукт «Нейросимулятор 5.0» [2]. Сами результаты прогнозирования представлены на рисунке 2. На гистограмме приведены результаты прогнозирования для случайных 100 фильмов из тестового множества. Средняя ошибка на тестовом множестве составила 10,2%.




Рисунок 2. Результаты сопоставления реального рейтинга фильмов с прогнозным

На рисунке 3 представлена гистограмма, показывающая распределение значимости параметров. Из графика видно, что наиболее значимым параметром является бюджет фильма. Кроме того, вторым по значимости параметром оказался год выпуска фильма, а на третьем месте разместился параметр, связанный с количеством лайков киноленты на Facebook.




Рисунок 3. Значимость параметров

Далее было выполнено исследование рейтингов кинолент методом «замораживания» [3, 4]. Его суть состоит в том, чтобы проанализировать, как изменяется выходной параметр при изменении одного из входных параметров.

Для анализа были выбраны 5 фильмов с различными исходными характеристиками. На рисунке 4 показана зависимость рейтинга фильма от количества лайков, которое было получено этой кинолентой на Facebook. Результаты показывают, что при неизменных остальных параметрах, при увеличении количества лайков рейтинг фильмов имеет незначительную тенденцию к снижению.




Рисунок 4. Зависимость рейтинга фильмов от количества лайков киноленты на Facebook

На рисунке 5 представлена зависимость рейтинга киноленты от количества лайков на странице режиссера на Facebook. Результаты показывают, что при неизменных других параметрах, при увеличении количества лайков на странице режиссера на Фейсбуке увеличивается и рейтинг фильма.




Рисунок 5. Зависимость рейтинга киноленты от количества лайков на странице режиссера на Facebook

На рисунке 6 представлена зависимость рейтинга фильма от количества лайков на Facebook всей съемочной группы киноленты. Результаты показывают, что при неизменных других параметрах, при увеличении количества лайков на Facebook у съемочной группы рейтинг фильма увеличивается.




Рисунок 6. Зависимость рейтинга киноленты от количества лайков на страницах людей съемочной группы на Facebook

Таким образом была построена нейросетевая модель, предназначенная для прогнозирования рейтинга фильма, основываясь на тех показателях, которые известны ещё до выхода фильма. Проведены исследования зависимости рейтинга фильма в зависимости от популярности режиссера, фильма и съемочной группы в социальной сети Facebook. Построены графики соответствующих зависимостей и сделаны соответствующие выводы.

Библиографический список

1. Электронный ресурс IMDb – крупнейшая база кинофильмов. Доступен по ссылке: <https://www.imdb.com>. Дата обращения 23.02.2020.
2. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
3. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007. – 271 с.
4. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5. – С. 48-56.
5. Ясницкий Л.Н., Белобородова Н.О., Медведева Е.Ю. Методика нейросетевого прогнозирования кассовых сборов кинофильмов // Финансовая аналитика: проблемы и решения. 2017. т. 10. Вып. 4. С. 449–463.
6. Ясницкий Л.Н., Плотников Д.И. Экономико-математическая нейросетевая модель для оптимизации финансовых затрат в кинобизнесе // Фундаментальные исследования. 2016. № 11 (часть 2). с. 339-342.

NEURAL NETWORK FORECAST OF THE WORLD FILM RATING AND DEPENDENCE OF THIS RATING ON THE POPULARITY OF FILMS IN SOCIAL NETWORKS

Poselentseva D.Y., Mikov R.O.

Perm State National Research University, 614990, Russia, Perm, Bukireva street,
15, octopus.diana@gmail.com, romasa37@gmail.com

This work is devoted to forecasting the world rating of a film based on the construction of a neural network system. The system allows you to predict the world rating of the film on the basis of eleven input parameters, such as the director, the number of reviews of critics about the film, the duration of the film (in minutes), leading actors, etc. The system also has the ability to identify trends in the world rating of the film depending on the output parameters.

Key words: artificial intelligence, neural network technologies, forecasting, world rating of films, film.

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ УСЛОВНОЙ ПРИБЫЛИ ОТ ПРОКАТА ФИЛЬМА

Сидоренко Дмитрий Олегович

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, dima.sidorenk@yandex.ru

В статье представлено описание разработки нейросетевой системы для оценки условной прибыли фильма. Под условной прибылью здесь понимается разность между кассовыми сборами фильма (выручкой) и бюджетом фильма. Система позволяет прогнозировать объем условной прибыли фильма по характеристикам как самого фильма, так и режиссеров, актеров. Было проведено ряд исследований, результаты которых приводятся в данной статье.

Ключевые слова: кинематограф, кинобизнес, финансы, кинопоиск, модель, нейронная сеть, прогноз, киноиндустрия, условная прибыль.

Введение. Ученые и руководители крупных компаний по производству фильмов тщательно изучают способы прогнозирования кассовых сборов с использованием метода математического моделирования. По словам многих аналитиков, прогнозирование точного дохода от фильма до его выхода является одной из самых сложных и важных задач для кинематографистов. Сложность заключается в том, что существует множество причин, которые влияют на успех фильма, начиная от бюджета фильма и его продолжительности и заканчивая ростом актера и временем года, когда снят фильм.

Многие режиссеры находятся в поисках экономико–математической модели на основе нейронной сети, которая смогла с высокой точностью предсказывать доход фильмов, поэтому тема является довольно актуальной.

Доказательством актуальности является большое количество статей по данной теме. Материалами, которые были использованы при выполнении данной работы, являются статьи студентов из Высшей Школы Экономики Белобородовой Н.О, Медведева Е.Ю [1] и студентов из Пермского Государственного университета Зимина И.В., Мироненко А.О [2], Плотникова Д.И [6], Митрофанова И.А., Иммис М.В. [7], кроме того соавтором всех статей также является научный руководитель студентов Ясницкий Л.В. Все статьи были взяты за основу при изучении предметной области. Стоит также отметить вклад ученых Прега и Касаванта, которые были первыми исследователями, применившими в кинобизнесе метод экономико – математического моделирования. В 1994 году они опубликовали

статью [8], в которой описали созданную регрессионную модель на основе выборки из 625 американских фильмов.

Как уже было сказано выше, сложность оценки условной прибыли представляет большое число параметров, которые нужно учесть при прогнозировании, поэтому сбор и анализ информации в данной работе имел определяющее значение. При поиске датасета было просмотрено множество статей в интернете, рассматривался вариант с датагенератором, но в итоге был найден датасет на сайте Kaggle [3], который и был взят за основу.

Набор данных состоит из следующих параметров: X1 – Год выхода на экраны, X2 – Продолжительность фильма (минуты), X3 – Является ли фильм продолжением? (2-не известно, 1-да, 0-нет), X4 – Возрастное ограничение, X5 – Главная страна-производитель (1- Афганистан 2-Гонконг, ..., 218-Босния и Герцеговина), X6 – Причастие других стран (1-да, 0-нет), X7 – Наличие похожих фильмов (1-да, 0-нет), X8 – Среди жанров есть «мелодрама» (1-да, 0-нет), X9 – Среди жанров есть «комедия» (1-да, 0-нет), X10 – Среди жанров есть «аниме» (1-да, 0-нет), X11 – Среди жанров есть «военный» (1-да, 0-нет), X12 – Среди жанров есть «боевик» (1-да, 0-нет), X13 – Среди жанров есть «документальный» (1-да, 0-нет), X14 – Среди жанров есть «спорт» (1-да, 0-нет), X15 – Среди жанров есть «триллер» (1-да, 0-нет), X16 – Среди жанров есть «криминал» (1-да, 0-нет), X17 – Среди жанров есть «мюзикл» (1-да, 0-нет), X18 – Среди жанров есть «драма» (1-да, 0-нет), X19 – Среди жанров есть «для взрослых» (1-да, 0-нет), X20 – Среди жанров есть «история» (1-да, 0-нет), X21 – Среди жанров есть «вестерн» (1-да, 0-нет), X22 – Среди жанров есть «приключения» (1-да, 0-нет), X23 – Среди жанров есть «фильм-нуар» (1-да, 0-нет), X24 – Среди жанров есть «концерт» (1-да, 0-нет), X25 – Среди жанров есть «короткометражка» (1-да, 0-нет), X26 – Среди жанров есть «ужас» (1-да, 0-нет), X27 – Среди жанров есть «мультфильм» (1-да, 0-нет), X28 – Среди жанров есть «фантастика» (1-да, 0-нет), X29 – Среди жанров есть «детектив» (1-да, 0-нет), X30 – Среди жанров есть «фэнтези» (1-да, 0-нет), X31 – Среди жанров есть «семейный» (1-да, 0-нет), X32 – Среди жанров есть «новости» (1-да, 0-нет), X33 – Среди жанров есть «музыка» (1-да, 0-нет), X34 – Наличие номинаций у актеров (1-да, 0-нет), X35 – Наличие номинаций у режиссёров (1-да, 0-нет), X36 – Общее количество актеров, X37 – Количество известных актеров, X38 – Общее количество режиссёров, X39 – Количество известных режиссёров, X40 – Общее количество продюсеров, X41 – Количество известных продюсеров, X42 – Общее количество сценаристов, X43 – Количество известных сценаристов, X44 – Общее количество художников, X45 – Количество известных художников, X46 – Общее количество монтажеров, X47 – Количество известных монтажеров, X48 – Общее количество операторов, X49 – Количество известных операторов, X50 – Количество актеров, X51 – Количество актрис, X52 – Количество актеров/актрис в браке, X53 – Количество актеров/актрис с детьми, X54 – Наличие актеров нетрадиционной ориентации (1 – Да, 0 – Нет), X55 – Средний возраст актеров, X56 – Средний рост актеров, X57 – Наличие

слогана фильма, X58 – Бюджет(млн. долларов). Выходной параметр: D1 – Условная прибыль (млн. долл.).

Итоговое множество для нейросети состоит из 1408 фильмов. Все данные были проверены на наличие пропусков. Итоговое множество впоследствии было разбито на два множества – обучающее и тестирующее.

Для проектирования искусственной нейронной сети была использована программа «Нейросимулятор 5» [4].

Средняя квадратичная относительная ошибка тестирования составила 12,13%, что можно назвать достойным результатом. Для сравнения результаты, представленные в статьях [1] и [2], равны 13,8 и 4,02 соответственно.

На рисунке 1 представлена гистограмма, демонстрирующая разницу между исходными значениями выходного параметра и прогнозируемого нейронной сетью.



Рисунок 1. Результат тестирования нейронной сети

На рисунке 2 представлена гистограмма, показывающая распределение значимости параметров.

Самыми значимыми входными параметрами оказались: продолжительность фильма, бюджет фильма, является ли фильм “аниме”, “является ли фильм семейным”. Таким образом, можно сказать, что модель правильно выявила значимые параметры, ведь действительно продолжительность и бюджет являются определяющими во многих случаях при оценке условной прибыли. Такие же наблюдения можно заметить в статьях моих предшественников [1][2].




Рисунок 2. Значимость параметров

Далее был выполнен ряд исследований пяти случайно выбранных фильмов. Исследования производились с помощью метода «замораживания» [5]. Его суть – в изменении значения одного из параметров и фиксирования всех остальных. К сожалению, определить название фильмов, выбранных для данного исследования, не представляется возможным.

На рисунке 3 представлена зависимость условной прибыли фильма от его продолжительности. По итогам проведенных исследований можно сказать, что при увеличении длительности, увеличивается и доход фильма. Это является фактом, люди охотнее посещают те картины, которые идут дольше.




Рисунок 3. Зависимость выручки фильма от продолжительности фильма

Плотников Д. И. в статье [7] провел исследования зависимости условной прибыли от бюджета фильма, которые показывают, что зачастую выгодно увеличивать бюджет фильма на 20 – 30 млн. долларов, увеличивая больше условная прибыль становится отрицательной. Для построенной модели были проведены аналогичные исследования с помощью метода “замораживания”. По результатам исследований оказалось, что при увеличении бюджета прибыль от картины падает. Это закономерность прослеживается во всех фильмах и не совпадает с результатами статьи [7]. Результаты в статье [7] наиболее близки к истине, а результаты данного исследования для построенной модели показывают ее недостатки.

На рисунке 4 показана зависимость условной прибыли от бюджета фильма для построенной нейросети.




Рисунок 4. Зависимость прибыли от бюджета фильма

Наконец третьим с использованием метода “замораживания” было проведено исследование зависимости условной прибыли картины от того, является ли она продолжением какой – либо линейки фильмов. По результатам исследований можно сказать, что это довольно значимый параметр, ведь для всех выбранных фильмов, условная прибыль для тех, которые являются продолжением, была больше. С одной стороны, это правильные выводы, зачастую так и происходит в реальной жизни. С другой стороны, если фильмы – предшественники были неудачными, то их продолжение скорее всего будет иметь невысокую или даже отрицательную условную прибыль, данные замечания не учитывались при разработке модели, но являются весьма важными критериями, которые нужно принимать во внимание. Стоит также отметить, что данный критерий не был принят во внимание ни одним из моих предшественников.

На рисунке 5 приведены результаты данного исследования.




Рисунок 5. Зависимость прибыли фильмов от того, являются они продолжением какой-либо линейки картин или нет

Заключение. Построена нейросетевая система, предназначенная для оценки условной прибыли фильмов. Модель является уникальной, но не лучшей из уже существующих. Если сравнивать с работами предшественников, то точно можно сказать, что были допущены ошибки. В первую очередь, ошибки связаны с не учётом некоторых довольно важных критериев. В будущем предлагается заняться улучшением датасета: провести тщательный анализ параметров, выявить и исключить те, что приводят к противоречащим результатам, добавить параметры, которые не такие явные на первый взгляд, но которые сильно влияют на правильность оценок. При доработке датасета модель может быть полезна в сфере кинематографа.

Библиографический список

1. Ясницкий Л.Н., Белобородова Н.О., Медведева Е.Ю. Методика нейросетевого прогнозирования кассовых сборов кинофильмов // Финансовая аналитика. – 2017. – т. 10. – №4. – С.449.
2. Ясницкий Л.Н., Зимин И.В., Мироненко А.О. Самоадаптируемая нейросетевая система оценки и прогнозирования мировых кассовых сборов фильма (статья еще не вышла).
3. Dataset from “KINPOISK” [Электронный ресурс] // <https://www.kaggle.com>. URL: <https://www.kaggle.com/nataliamityagina/dataset-from-kinopoisk> (дата обращения: 16.06.2020).
4. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

5. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007. – 271 с.
6. Ясницкий Л.Н., Плотников Д.И. Экономико-математическая нейросетевая модель для оптимизации финансовых затрат в кинобизнесе // Фундаментальные исследования. – 2016. – № 11-2. – С. 339-342;
7. Yasnitsky L.N., Mitrofanov I.A., Immis M.V. (2020) Intelligent System for Prediction Box Office of the Film. In: Antipova T. (eds) Integrated Science in Digital Age. ICIS 2019. Lecture Notes in Networks and Systems, vol 78. Pp. 18-25. Springer, Cham.
8. Prag J. and Casavant J. An Empirical Study of the Determinants of Revenue and Marketing Expenditures in the Motion Picture Industry // Journal of Cultural Economics. – 1994. – No 18(3). – Pp. 217-235.

NEURAL NETWORK ESTIMATION SYSTEM OF FILM PROFIT IN WORLD RENT

Sidorenko Dmitriy O.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, dmitriysidorenko59@gmail.com

The article provides a description of the development of a neural network system for evaluating film profits. The system allows you to predict the amount of profit of the film on the characteristics of the film itself, as well as directors and actors. A number of studies have been conducted, the results of which are given in this article.

Keywords: cinema, film business, world box office, finance, cinema search, model, neural network, forecast, film industry, profit.

УДК 51.76

ИСПОЛЬЗОВАНИЕ ФУНКЦИОНАЛЬНОЙ ПРЕДОБРАБОТКИ ЗАШУМЛЕННЫХ ДАННЫХ В ЗАДАЧАХ КЛАССИФИКАЦИИ

Русаков Сергей Владимирович, Чупин Дмитрий Алексеевич

Пермский государственный национальный исследовательский университет,
Механико-математический факультет, ПМИ, 614990, Россия, г. Пермь,
ул. Букирева, 15, mr.dmitriych@gmail.com, rusakov@psu.ru

Проведена функциональная обработка данных двумя последовательными алгоритмами. Написана программа, позволяющая произвести

функциональную предобработку данных и улучшить показатели обучения нейронной сети на примере задачи медицинской диагностики.

Ключевые слова: кардиология, сердечно-сосудистые заболевания, гипотония, функциональная предобработка, нейронная сеть.

1. Актуальность. В данный момент сердечно-сосудистые заболевания являются основной причиной смерти во всем мире. По оценкам ВОЗ в 2016 году от ССЗ умерло 17,9 миллиона человек, что составило около трети всех случаев в мире. 85% данных смертей произошло в результате сердечного приступа или инсульта [4].

Предварительная обработка данных является важным этапом в процессе интеллектуального анализа данных. В том случае, если у нас имеется много нерелевантной и избыточной информации или зашумленных и ненадежных данных, то обучение и анализ этих данных является более сложным. Этапы подготовки и фильтрации данных могут занимать значительное время в процессе обработки, поэтому в качестве их альтернативы рассмотрена нормализация данных [1].

2. Предварительная обработка данных. У нас имеется выборка X . На первом шаге вычисляется среднее значение данной выборки X_{avg} , а также среднеквадратичное отклонение σ .

Для каждого элемента выборки вычисляется новое значение \tilde{x}_i при помощи одного из методов отсева грубых погрешностей. Выбор данного метода обусловлен небольшим объемом выборки: [2]

$$\tilde{x}_i = \frac{x_i - X_{avg}}{\sigma}$$

В результате этого наши значения приближены к интервалу $[-1;1]$, но все еще имеются \tilde{x}_i , которые лежат за его пределами.

На следующем шаге производится нормализация при помощи функции гиперболического тангенса, которая приведет данные значения к интервалу $[-1;1]$.

Для каждого \tilde{x}_i выполним следующее преобразование [3]:

$$\hat{x}_i = F(\tilde{x}_i)$$

$$F(a * z) = th(a * z) = \frac{e^{a*z} - e^{-a*z}}{e^{a*z} + e^{-a*z}}, -1 < a < 1$$

3. Построение нейросетевой модели. Имеется выборка из 106 человек, у 70 из которых была выявлена артериальная гипотензия. У всех пациентов было измерено 28 показателей здоровья. Был проведен сравнительный анализ 5 нейронных сетей и в результате была получена следующая нейронная сеть с наилучшими показателями: 1 скрытый слой и 3 нейрона на данном слое [5].

Квадратичная ошибка была вычислена при помощи следующей формулы:

$$E = \frac{1}{n} * \sum_{j=0}^{n-1} (t_j - o_j)^2,$$

Где t_j – ожидаемый выход j -го нейрона, o_j – выход j -го нейрона.

Далее были построены нейронные сети для каждого из этапов функциональной предобработки:

1. Без предобработки графическое изображение обучения представлено на рисунке 1. На первоначальных данных квадратичная ошибка равна 29.99, что является высоким показателем и ее требуется уменьшить.




Рисунок 1. График обучения нейронной сети на начальном этапе

2. В результате первой предобработки получаем результаты, представленные на рисунке 2. На данном этапе квадратичная ошибка равна 20.56.




Рисунок 25. График обучения нейронной сети на первом этапе.

Сильные скачки на графике обуславливаются наличием выбросов, которые будут нейтрализоваться на следующем шаге.

3. Нормировка при помощи функции гиперболического тангенса дала результаты, представленные на рисунке 3. Квадратичная ошибка составила 17,87.




Рисунок 3. График обучения нейронной сети с использованием полного набора входных параметров

Обсуждение результатов и заключение. В результате выполненных исследований были снижены ошибки обучения и тестирования нейронной сети, которая строилась на основе этих данных. Показатель квадратичной

ошибки обучения снизился практически в полтора раза. Также было показано, что функциональная предобработка данных позволяет избавиться от нерелевантной и избыточной информации, а также от зашумленных данных. Предобработка уменьшает размерность данных и позволяет алгоритмам обучения работать быстрее и эффективнее, в некоторых случаях улучшая точность дальнейшей классификации.

Библиографический список

1. S. V. Kotsiantis, D. Kanellopoulos and P. E. Pintelas. Data Preprocessing for Supervised Learning // International journal of computer science. 2006.
2. Гусев А.Л., Окунев А.А. Автоматизированное решение задач прогнозирования методом экстраполяции ошибки нейросети // Перспективы науки. – Тамбов, 2018. – С. 28–32.
3. Лузина Е.Ю. Методы предварительной обработки зашумленных данных на примере задачи классификации гипотоников: выпускная квалификационная работа бакалавра / Лузина Е.Ю. Пермь: Пермский государственный научный исследовательский университет, 2019. 68 с.
4. Всемирная организация здравоохранения. – URL: [https://www.who.int/ru/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/ru/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) 16.12.2019.
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

FUNCTIONAL PREPROCESSING OF NOISY DATA IN CLASSIFICATION TASKS

Rusakov Sergey Vladimirovich, Chupin Dmitriy Alekseevich
Perm State University
Str. Bukireva, 15, Perm, Russia, 614990, rusakov@psu.ru

Functional data processing was carried out by two sequential algorithms. A program was written to enable functional data preprocessing and improve neural network learning performance.

Ключевые слова: cardiology, cardiovascular disease, hypotension, functional preprocessing, neural network.

ПРОГНОЗИРОВАНИЕ ЗАНЯТОГО МЕСТА ФУТБОЛЬНОЙ КОМАНДЫ В ЛИГЕ ЧЕМПИОНОВ

Гришин Никита Андреевич

Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15, nike04@mail.ru

В статье представлено описание разработки динамической нейросетевой системы для прогнозирования места и рекомендации по улучшению результативности футбольных команд в Лиге чемпионов с учетом их индивидуальных особенностей.

Ключевые слова: искусственный интеллект, нейросетевые технологии, футбол, прогнозирование, результативность, средний возраст игроков, возраст тренера, Лига чемпионов, количество бомбардиров.

Введение. В 1955 году был основан кубок европейских чемпионов, потихоньку он стал набирать популярность. Позже в 1992 году формат турнира был изменен, также изменено название, став Лигой чемпионов. Сейчас этот турнир является одним из самых популярных в мире. У этого турнира много спонсоров, большой интерес публики, большое количество букмекеров и тех, кто занимается ставками на результаты матчей. Именно таким людям может быть интересна данная работа.

В качестве предметной области был выбран ежегодный чемпионат под названием «Лига чемпионов». Представляет интерес наблюдать за этим чемпионатом и каждый раз до конца прогнозировать, кто выиграет турнир.

Данная работа актуальна, в связи с тем, что турнир в сезоне 2019-2020 не доигран, из-за эпидемии коронавируса, но групповой этап уже сыгран, и начаты игры 1/8 финала, с помощью проделанной работы можно спрогнозировать какое место будет занято командой. А также можно помочь командам создавать стратегию подготовки к чемпионату. При создании нейросетевой математической модели, предназначенной для прогнозирования занимаемого места, было сформировано множество примеров, полученных путем анализа результатов команд в Лиге чемпионов 2014 – 2019 годов. Информация о командах и их результатах была взята из базы данных сайтов [1] и [2]. Проанализировав статью [8], в качестве входных параметров были взяты следующие данные: X1 – четность сезона (1-четный, 2-нечетный), X2 – средний возраст игроков в команде, X3 – Возраст тренера, X4 – Сколько лет тренер тренирует клуб, X5 – Число забитых мячей клуба в групповых матчах, X6 – Число пропущенных мячей клуба в групповом этапе, X7 – Количество бомбардиров команды, X8 – Входит ли вратарь в список лучших вратарей мира (1 – да, 2 – нет), X9 –

Присутствуют ли лучшие футболисты XXI века (1-да, 2-нет), X10 – Лидер или аутсайдер (1-лидер, 2-аутсайдер).

Выходной параметр кодировал место, занимаемое командой в Лиге чемпионов.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [6] по методике [7]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет десять входных нейронов, один выходной и один скрытый слой с тремя нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 16 примеров. Средняя ошибка тестирования составила 14.05%, что можно считать приемлемым результатом. На Рисунок 26 представлена гистограмма, демонстрирующая разницу между фактического и прогнозируемого нейросетью занимаемого места случайно отобранных 16 команд из тестирующего множества.




Рисунок 26-Результат тестирования нейронной сети

Из результатов, изображенных на Рисунок 26, можно сделать вывод об адекватной работе спроектированной нейронной сети.

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рисунке 2.




Рисунок 27 – Значимость входных параметров нейросетевой модели

Как видно из Рисунок 27, наиболее значимыми параметрами являются: «количество бомбардиров», «четность сезона», «сколько лет тренирует команду», «входит ли вратарь в топ вратарей». Параметр, оказывающий наименьшее влияние – «возраст тренера».

На рис. 3 – 5 приведены результаты дальнейших исследований нейросетевой математической модели, построенной с учетом всех входных параметров. Исследование влияния изменения входных параметров на результат команды выполнены путем «замораживания» (фиксации) одних параметров и постепенного изменения других входных параметров при одновременном наблюдении за значением выхода сети. Для этой цели были отобраны 6 команд, информация, о параметрах которых, отражена в **Таблица 8**.

Таблица 8 – Характеристики команд, выбранных для исследования

	Ювентус	Челси	Барселона	Севилья	Реал Мадрид	Манчестер Сити
X1	1	2	2	1	2	1
X2	29	26	29	27	27	27
X3	46	68	47	55	45	47
X4	1	1	2	1	3	3
X5	7	13	6	7	17	16
X6	4	3	3	3	7	6
X7	6	7	8	8	11	9
X8	1	1	1	2	1	1
X9	1	1	1	2	1	1
X10	1	1	1	2	1	1
D1	2	10	10	10	1	10

На Рисунок 28 показан график зависимости занимаемого места в чемпионате команды от четности сезона. Из графика хорошо видно, если

команда в четном сезоне заняла призовое место, то в нечетном результат отрицательный или наоборот. Это говорит о том, что четность сезона действительно сильно влияет на выигрыш в данном чемпионате.




Рисунок 28 – Зависимость занимаемого места от четности сезона

На рисунке 4 продемонстрирована зависимость занимаемого места футбольной командой в чемпионате от количества бомбардиров. На графике отчетливо отслеживается эта зависимость, чем больше бомбардиров, тем выше результат команды.




Рисунок 29 – Зависимость результатов команд от количества бомбардиров в команде

На рисунке 5 изображена зависимость результатов футбольных команд от статуса вратаря. Из этого графика можем сделать вывод, что вратарь сильно влияет на успешный результат, если команда занимает призовое место с топ вратарем, то с вратарем ниже уровнем, результат меняется в противоположную сторону.




Рисунок 30 – Результаты команд от статуса вратаря

Полученные результаты исследований не противоречат реальности, что подтверждает, что спроектированную нейронную сеть можно считать пригодной для прогнозирования занимаемого места футбольной команды в Лиге чемпионов.

Прогноз на 2019-2020. По собранным данным, не доигранного чемпионата из-за карантина, футбольных команд в этом сезоне на групповом этапе были спрогнозированы результаты с помощью разработанной нейросетевой модели. На рисунке 6 изображены спрогнозированные результаты на 2019-2020 сезон Лиги чемпионов. В ходе эксперимента, оказалось, что, согласно нашему прогнозу, призовые места могут занять Ливерпуль, Атлетико Мадрид и Манчестер Сити.




Рисунок 6 – прогноз на 2019-2020 сезон Лиги чемпионов

Заключение. Разработана нейросетевая математическая модель, предназначенная для прогнозирования места футбольной команды в Лиге чемпионов, которая может быть полезна для команд, желающих занять высокое место в данном чемпионате, а именно: может помочь в планировании действий в следующем сезоне для достижения максимального результата.

Библиографический список

1. Лига чемпионов 2014/2015 / Результаты матчей, URL:<https://soccer365.ru/competitions/19/2014-2015/results/> (Дата обращения 25.06.2020).
2. Статистика игроков/Бомбардиры/Лига чемпионов/Футбол/ Чемпионат, URL:https://www.championat.com/football/_ucl/tournament/2989/statistic/player/bombardir/ (Дата обращения 25.06.2020).
3. Ясницкий Л.Н. Введение в искусственный интеллект. – М.: Издательский центр «Академия», 2005. – 176 с.
4. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Перм. Ун-т. – Пермь, 2007. – 167 с.
5. Ясницкий Л.Н. Пермская научная школа искусственного интеллекта и ее инновационные проекты / Л.Н.Ясницкий, В.В.Бондарь, С.Н.Бурдин и др.; под ред. Л.Н.Ясницкого. – 2-е изд. – Москва-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. – 75 с
6. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
7. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

8. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по футболу Евро-2016 методом нейросетевого моделирования // Вестник спортивной науки. № 5. 2015. С. 15-20.

FORECAST OF THE EMPLOYED FOOTBALL TEAM PLACE IN THE CHAMPIONS LEAGUE

Grishin Nikita Andreevich

Perm State National Research University, PMI. 614990, Russia, Perm, ul. Bukireva, 15, nike04@mail.ru

The article describes the development of a dynamic neural network system for predicting a place and recommendations for improving the performance of football teams in the Champions League, taking into account their individual characteristics. **Ke ywords:** artificial intelligence, neural network technologies, football, forecasting, performance, average age of players, age of coach, Champions League, number of scorers.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ И АНАЛИЗА ПОСЕЩАЕМОСТИ МАТЧЕЙ РФПЛ

Осипов Андрей Александрович, Ратченко Андрей Юрьевич

Пермский государственный национальный исследовательский университет, ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15
OsipovAA146@yandex.ru, andreirat00@gmail.com

В статье представлен процесс разработки экспертной системы, осуществляющей прогноз посещаемости футбольных матчей РФПЛ. Экспериментальным путем была получена оптимальная нейросетевая модель, а также определены факторы предметной области, в той или иной степени, влияющие на посещаемость футбольного матча. Был приведен подробный анализ влияния каждого параметра на итоговый результат прогноза, а также составлены рекомендации, увеличивающие потенциальную посещаемость стадиона.

Ключевые слова: искусственный интеллект, нейронная сеть, закономерности, спорт, прогнозирование, посещаемость, моделирование, футбол.

Введение. Сегодня спорт – это направление деятельности человека, в котором постоянно присутствует ощутимая доля случайности. Спортивное прогнозирование, в частности количественная оценка зрителей на футбольном матче, является перспективным направлением для нейросетевого анализа. Информация о количестве болельщиков на грядущем матче дает возможность рекламным агентствам скорректировать расценки на рекламную кампанию бренда непосредственно на стадионе. Также данные о посещаемости стадиона могут быть полезны силовым структурам, осуществляющим защиту населения от радикальных футбольных болельщиков. В таком случае количество выделенной охраны прямо пропорционально количеству болельщиков на спортивном событии [14].

Непредсказуемость поведения радикально-настроенных футбольных болельщиков ставит под угрозу безопасность жизни людей и сохранность прилегающей к стадиону инфраструктуры. Помимо аспекта безопасности, оценка заинтересованных в конкретном футбольном матче зрителей является определяющей для рекламных агентств, которые устанавливают тарифы на рекламную кампанию какого-либо продукта на стадионе. Из этого следует, что любое агентство сможет спрогнозировать прибыль и возможные риски с сравнительно небольшой погрешностью.

Целью настоящей работы является попытка применения современных методов искусственного интеллекта для количественного прогнозирования посещаемости футбольного матча.

На начальном этапе изучения проблемы были изучены исследовательские работы прошлых лет со смежной предметной областью [5-11]. Ключевую роль в формировании нейросетевой модели играет выбор значимых входных параметров, влияющих на результат прогнозирования. При изначальном проектировании модели присутствовали следующие параметры: температура воздуха, наличие осадков, влажность воздуха, наличие крыши у стадиона, расстояние между футбольными клубами в километрах, взятые из научной статьи о прогнозировании посещаемости футбольных матчей испанской плей лиги за авторством Mehmet Şahin и Rızzvan Erol [11]. После анализа этих параметров выяснилось, что величина их значимости стремится к нулю, вопреки ожиданиям. При анализе статей [6-8] было сформировано конечное множество наиболее значимых входных параметров, а также определено соотношение множества обучающих и тестовых примеров. Таким образом, нейросетевая модель содержит вектор из 7 входных сигналов:

X1 – День недели. Этот параметр кодируется следующим образом: 1 – понедельник, 2 – вторник, 3 – среда, 4 – четверг, 5 – пятница, 6 – суббота, 7 – воскресенье.

X2 – Вместимость стадиона. Характеризуется числом посадочных мест. Информация о каждом стадионе взята с сайта [12].

X3 – Коэффициент заполненности стадиона. Вычисляется путем нахождения частного среднего арифметического числа зрителей за

последние n матчей и вместимостью стадиона. Следовательно, значение коэффициента лежит в пределах от 0 до 1.

X4. – Население города, в котором состоится футбольный матч. Этот параметр необходим для более точного прогнозирования посещаемости спортивного события. В зависимости от текущего тура и рейтинга клуба, играющего в гостях, количество зрителей на стадионе может варьироваться.

X5 – Рейтинг команды, играющей в гостях. Параметр обозначает место клуба в турнирной таблице РФПЛ. Принимает значения от 1 до 16. Информация о рейтингах команд взята с сайта [13].

X6 – Этап РФПЛ (тур). Принимает значения от 1 до 30.

X7 – Время начала футбольного матча. Время начала встречи в перевод на 24-ех часовой формат. Например: 22:00 – 22, 14:00 – 14, 19:30 – 20.

Модель имеет 1 выходной параметр

Y1 – Количество зрителей.

Всего было составлено 220 футбольных матчей РФПЛ сезона 2018/2019, из них 200 использовались для обучения, 20 для тестирования. Нейронная сеть персептронного типа была спроектирована, протестирована и оптимизирована по методике Пермской научной школы искусственного интеллекта [1-3].

Используя теорему Арнольда-Колмогорова-Хехт-Нильсена [2] было определено оптимальное количество нейронов скрытого слоя.

Таким образом, спроектированный персептрон имеет входной, скрытый и выходной слой с 7, 24 и 1 нейронами соответственно. Функция активации входного слоя – гиперболический тангенс. На тестирующем множестве примеров была достигнута среднеквадратичная погрешность 15%.

После того как работа нейросети проверена на тестовых примерах (рисунок 1), и установлена адекватность нейросетевой математической модели, можно приступать к ее исследованию.




Рисунок 1. Сравнение реальной и прогнозируемой посещаемостей

Прежде всего была определена значимость входных параметров сети по методике [1-3] путем поочередного исключения входных нейронов и наблюдением за погрешностью. Значимость параметров подразумевает степень их влияния на выходной результат. Рисунок 2 демонстрирует гистограмму значимости параметров.




Рисунок 2. Гистограмма значимости параметров

Из гистограммы следует, что наиболее значимыми параметрами являются: вместимость стадиона, коэффициент заполненности стадиона, этап РФПЛ (тур), в то время как рейтинг команды, день недели, численность города, принимающего матч и прочее вносят сравнительно меньший вклад в итоговый результат прогноза.

Применение методов искусственного интеллекта помогает не только предсказывать исход событий, но и получать рекомендации, позволяющие активно влиять на итоговый результат. Далее был рассмотрен один из матчей РФПЛ сезона 2018/2019. Изменяя значения параметров входного слоя, было проанализировано изменение числа болельщиков на стадионе.

В качестве анализируемого матча, была взята встреча «Локомотив Москва» и «Зенит Санкт-Петербург» от 7 апреля 2019 года. Информация о матче взята с сайта [12].

При изменении входного параметра времени начала встречи, выявлена следующая закономерность, представленная на рисунке 3. Из диаграммы видно, что максимальная посещаемость футбольного матча достигается в период с 18:00 по 19:00. В дневное время количество болельщиков значительно уменьшается, а после 19:00 наблюдается небольшой спад посещаемости. Таким образом, можно сделать вывод, что максимальный трафик на стадионе следует ожидать после 18:00.




Рисунок 3. График зависимости посещаемости матча от времени начала встречи

Теперь рассмотрим влияние номера тура на посещаемость стадиона (рисунок 4). В качестве анализируемых стадионов были выбраны: «РЖД Арена», «Самара Арена», «Ростов Арена». Из графического представления следует, что во время первых недель начала нового сезона РФПЛ, вне зависимости от стадиона, рост и падение количества болельщиков являются незначительными. За неизменным состоянием графика следует падение числа футбольных зрителей к середине плей лиги на всех анализируемых стадионах. Но, когда РФПЛ подходит к завершению, интерес зрителей в футбольных встречах растет прямо пропорционально посещаемости, в конечном итоге превышая кол-во зрителей на стадионе в первых турах плей лиги. Таким образом, можно отметить, что заполненность стадиона напрямую зависит от тура.




Рисунок 4. Зависимость посещаемости от тура

Помимо приведенных выше параметров, на итоговый результат модели персептрона влияет день недели, в который происходит футбольная встреча. Проанализировав посещаемость пяти разных стадионов с разным значением

соответствующего параметра, была построена диаграмма, представленная на рисунке 5. Здесь использована следующая кодировка: 1 – «Арена Химки», 2 – «Стадион Газовик», 3 – «Екатеринбург Арена», 4 – «Казань Арена», 5 – Стадион «Арсенал». Так как все матчи, составляющие множество обучающих и тестовых примеров, проходили в пятницу, субботу, воскресенье и понедельник, остальные дни недели в диаграмме не были учтены. В конечном итоге было установлено, что в воскресенье посещаемость достигает своего максимума, в то время как понедельник, наоборот, является наименее благоприятным для проведения матча с точки зрения посещаемости.




Рисунок 5. Диаграмма зависимости посещаемости от дня недели

Также была рассмотрена зависимость посещаемости футбольного матча от рейтинга команды соперника на примере отдельно взятой встречи. В качестве сравниваемых клубов выступали «Зенит», «Локомотив» и «Краснодар». Уменьшение параметра рейтинга конкретной команды, играющей в гостях, значительно влияет на посещаемость, что видно из графика на рисунке 6. Стоит отметить, что если изначальная посещаемость стадиона мала, то ее дальнейшее падение несущественно.




Рисунок 6. Диаграмма зависимости посещаемости от рейтинга команды противника

Заключение. Спроектированная нейросетевая модель определяет посещаемость конкретного матча России по футболу с сравнительно небольшой погрешностью (10-15%). Из этого следует, что математическая модель персептрона может быть рекомендована спортивным клубам для регулирования цены на билет, а также рекламным агентствам, которые заинтересованы в данных о трафике на стадионе. Кроме этого, можно сделать некоторые выводы касательно увеличения посещаемости матчей. Для этого футбольным клубам следует улучшать инфраструктуру своего стадиона, увеличивать вместимость, так как, согласно исследованию, посещаемость пропорциональна вместимости стадиона, следовательно, людей привлекают более вместительные и современные стадионы даже не в самых крупных городах России. Помимо этого, стоит отметить, что пик посещаемости достигается в выходные дни, в частности, в воскресенье в 18:00-19:00 часов. Поэтому матчи команд с лидирующим местом в рейтинге следует проводить именно в это время для получения максимальной прибыли.

Библиографический список.

1. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. – 2015. – № 5. – С. 48-56.
2. Ясницкий Л.Н. Интеллектуальные системы: учебник. – М.: Лаборатория знаний, 2016. 221с.
3. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод пособие / Л. Н. Ясницкий; Пермь. Ун-т. – Пермь, 2007. – 271 с.
4. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0 // Свидетельство о

5. государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
6. Москвичева К. В., Мальцева А. В., Дюкина Т. В. Анализ динамики факторов, влияющих на посещаемость матчей по футболу // Санкт-Петербургский государственный университет, г. Санкт-Петербург, 2016. 5с.
7. Ясницкий Л.Н., Павлов И.В., Черепанов Ф.М. Прогнозирование результатов олимпийских игр 2014 года в неофициальном командном зачете методами искусственного интеллекта // Современные проблемы науки и образования. – 2013. – № 6; URL: <http://www.science-education.ru/113-11206> (дата обращения: 22.06.2020).
8. Ясницкий Л.Н., Внукова О.В., Черепанов Ф.М. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта // Современные проблемы науки и образования. – 2014. – № 1; URL: <http://www.science-education.ru/115-11339> (дата обращения: 22.06.2020).
9. Ясницкий Л.Н., Кировоса А.В., Ратегова А.В., Черепанов Ф.М. Прогноз результатов чемпионата мира-2015 по легкой атлетике методами искусственного интеллекта // Современные проблемы науки и образования. – 2014. – № 4. URL: www.science-education.ru/118-14423 (дата обращения: 22.06.2020)
10. Ясницкий Л.Н., Кировоса А.В., Ратегова А.В., Черепанов Ф.М. Методика прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 3. С. 90-97.
11. Jaume García and Plácido Rodríguez. The determinants of football match attendance revisited: Empirical evidence from the Spanish football league // Expert System. – Pp. 2-30.
12. Mehmet Şahin and Rızvan Erol. Prediction of Attendance Demand in European Football Games: Comparison of ANFIS, Fuzzy Logic, and ANN // Expert System. – Received 2018 Apr 19; Accepted 2018 Jul 5. – Pp. 3-10.
13. SOCCERWAY [сайт]. URL: <https://ru.soccerway.com/> (дата обращения: 22.06.2020)
14. Чемпионат [сайт]. URL: <https://www.championat.com/> (дата обращения: 22.06.2020)
15. Wikipedia. Массовые беспорядки в Москве [сайт]. URL: [https://ru.wikipedia.org/wiki/%D0%9C%D0%B0%D1%81%D1%81%D0%BE%D0%B2%D1%8B%D0%B5_%D0%B1%D0%B5%D1%81%D0%BF%D0%BE%D1%80%D1%8F%D0%B4%D0%BA%D0%B8_%D0%B2_%D0%9C%D0%BE%D1%81%D0%BA%D0%B2%D0%B5_\(2002\)](https://ru.wikipedia.org/wiki/%D0%9C%D0%B0%D1%81%D1%81%D0%BE%D0%B2%D1%8B%D0%B5_%D0%B1%D0%B5%D1%81%D0%BF%D0%BE%D1%80%D1%8F%D0%B4%D0%BA%D0%B8_%D0%B2_%D0%9C%D0%BE%D1%81%D0%BA%D0%B2%D0%B5_(2002)) (дата обращения: 22.06.2020)

ВЛИЯНИЕ РАСПРОСТРАНЕНИЯ АДДИТИВНЫХ ТЕХНОЛОГИЙ НА ЭКОЛОГИЧЕСКУЮ ОБСТАНОВКУ⁸⁰

Курушин Даниил Сергеевич

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, Комсомольский проспект, д. 29, dan973@yandex.ru

Шоломова Анна Игоревна

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29,
sholomova1997@email.ru

В данной статье рассматриваются аддитивные технологии, их процессы, технологии и используемые материалы для изготовления деталей. Приведены преимущества аддитивных технологий в сравнении с традиционным производством. Рассмотрено влияние аддитивных технологий на экологию, выявлены основные экологические проблемы, связанные с традиционным производством, а именно: огромное потребление энергии, большое количество отходов материалов – материал используется неэффективно, при фрезеровании может образоваться до 95% отходов, влияние на состояние воздуха, воды и почвы – токсичные вещества, образованные при производстве, попадают в окружающую среду, неоптимальное конструирование моделей – излишне тяжелые и неэффективные модели, и как аддитивные технологии решают данные проблемы. Также рассмотрены основные этапы аддитивного производства.

Ключевые слова: аддитивные технологии, экология, экологические проблемы, 3D моделирование, трехмерная печать.

Относительно новые технологии, аддитивные, резко вырвались вперед, заняли прочную позицию самых передовых технологий и являются очень востребованными во всем мире. Именно Чарльзу Халлу принадлежит создание данного вида технологий, Халл сконструировал первый стереолитографический трехмерный принтер в 1986 году. Но популярной данная технология стала в 21 веке, когда появилась возможность печати из металлических материалов, это стало прорывом в производстве, основой промышленной революции.

Аддитивные технологии или Additive Manufacturing представляют собой послойное наращивание, поэтапное добавление материала на основу,

⁸⁰ Публикация подготовлена при финансовой поддержке РФФИ (грант № 02-01-00701 и 03-01-06350-МАС) и Американского Фонда Гражданских Исследований и Развития (грант PE-009-0).

© Курушин Д.С., Шоломова А.И., 2020

плоскую платформу. Более распространенное название данных технологий 3D-печать, но именно термин «аддитивные технологии» утвержден организациями ASTM и ISO. В указанном стандарте ISO/ASTM 52900 описываемые технологии имеют следующее определение: аддитивные технологии – это изготовление объектов путем нанесения материала печатной головкой, с помощью сопла или другой технологии печати.

Традиционное производство детали требует заготовку, для получения нужной модели от нее отсекается лишнее, то есть вычитается, поэтому остается много материала, который в последствии использовать будет можно, но потребуются дополнительные ресурсы для его переработки, что отразится на стоимости такого изделия, аддитивные технологии напротив создают деталь с нуля, используют необходимое для модели количество материала, что является выгодным для производства, так как при традиционных способах изготовления потери сырья могут достигать 85%. То есть принцип аддитивных технологий – сложение, а не вычитание.

Стоит упомянуть еще несколько преимуществ этого вида технологий. Во-первых, модели созданные на компьютере можно отправить по сети в любую точку мира, то есть появляется мобильность производства, 3D принтер заменит большое количество оборудования. Во-вторых, уменьшение количества комплектующих частей детали, при традиционном методе производства для детали может требоваться много различных запчастей, которые позже нужно будет соединить, а 3D печать создаст деталь быстрее из специального материала. Еще один плюс аддитивных технологий – снижение веса детали, это важно, например, для авиационной промышленности. Также отметим штучное изготовление детали любой формы, мелкосерийное производство, использующееся в медицине и авиационно-космической промышленности.

Самое главное преимущество аддитивных технологий в их экологичности. На данный момент вопрос об экологии очень важен, экологическое производство – это сокращение количества потребляемой энергии и используемых материалов, такое сокращение может помочь, например, замедлить глобальное потепление.

В промышленном производстве существует ряд глобальных экологических проблем:

1. Огромное потребление энергии;
2. Большое количество отходов материалов – материал используется неэффективно, при фрезеровании может образоваться до 95% отходов;
3. Влияние на состояние воздуха, воды и почвы – токсичные вещества, образованные при производстве, попадают в окружающую среду;
4. Неоптимальное конструирование моделей – излишне тяжелые и неэффективные модели.

Вышеперечисленные недостатки классического производства устраняет полностью или частично 3D печать.

Доставка сырья на производство, изготовление и транспортировка готового продукта требуют больших затрат энергии. Выбросы углерода (или

других потенциально еще более опасных элементов), связанные с продажей, например, одного сотового телефона – огромны. Телефон пройдет через сотни поставщиков, проедет тысячи километров, то есть, пройдет через несколько уровней распространения продукции, прежде чем попадет в руки покупателя.

Трехмерная печать не решит эти проблемы, но может сократить количество этапов распространения, так как позволяет производить в одном месте большое количество разных частей для нужной детали. Необходимость в закупке деталей с других производств исчезнет, уменьшится уровень транспортировок, поэтому снизится количество выбросов углерода.

При традиционном методе изготовления изделий, материал отрезается от блока, отрезанные части становятся отходами производства, для переработки или утилизации которых требуются дополнительные энергия и ресурсы, используются потенциально вредные методы. Более того для добычи этих ресурсов задействованы крайне опасные для экологии методы, поэтому неэффективное использование ресурсов усугубляет наносимый урон. Трехмерная печать решает эту проблему, аддитивный процесс, при котором материал наслаивается поэтапно, практически не оставляет отходов. В результате классический метод обработки изделия дает около 95% отходов, а использование аддитивных технологий менее 1%.

Определенные виды металлообработки, в первую очередь обработка с ЧПУ и литье металла под давлением, требуют использования токсичных веществ в процессе производства. Масла и смазки, необходимые для правильной работы станков с ЧПУ, часто опасны для окружающей среды. В процессе отделки этих деталей также могут использоваться жидкости, которые при неправильном обращении могут вызвать повреждения. Точно так же при литье металла под давлением используется каталитический процесс удаления связующих, который требует использования опасных продуктов, которые очень вредны для окружающей среды. Аддитивный же процесс не образует токсичных побочных продуктов, то есть не наносит вред качеству воздуха и воды.

3D-печать позволяет изготавливать детали со сложной внутренней геометрией, часто способами, которыми невозможно создать ее при традиционном производстве. Изменения в конструкции изделия могут быть выполнены без ущерба для функциональности. Это позволяет снизить стоимость и время выполнения заказа за счет упрощения производственного процесса, а также дает значительные экологические преимущества.

Экологическая безопасность аддитивных технологий связана с низким количеством выбрасываемых отходов производства, сокращением потребления значительного объема ресурсов и энергии, снижению выбросов загрязняющих веществ.

Перейдем к рассмотрению процессов, технологий и материалов аддитивных технологий.

Аддитивное производство использует разные процессы послойного создания детали, например, такие как: экструзии, разбрызгивание (струйное напыление), УФ-отверждения, ламинирование, сплавление материалов.

Существуют следующие аддитивные технологии создания изделия:

- FDM (Fused deposition modeling) – изделие формируется послойно из расплавленной пластиковой нити.

- CJP (ColorJet printing) – единственная в мире 3d полноцветная печать с принципом склеивания порошка, состоящего из гипса.

- SLS (Selective Laser Sintering) – технология лазерного запекания, при которой образуются особо прочные объекты любых размеров.

- MJM (MultiJet Modeling) многоструйное 3d моделирование с использованием фотополимеров и воска.

- SLA (Laser Stereolithography) – с помощью лазера происходит послойное отвердевание жидкого полимера.

Основными материалами, используемыми в аддитивных процессах, являются: воск, пастообразные пластики, УФ- и фотоотверждаемые жидкие фотополимеры, керамонаполненные жидкие фотополимеры, гипсовый порошок, полистирол в виде порошка, стеклонаполненные, угленаполненные и металонаполненные полиамиды в виде порошка, металические сплавы в виде порошка и т. д.

Данный вид технологий используют для создания физических моделей, прототипов, образцов, инструментальной оснастки и производства пластиковых, металлических, керамических, стеклянных, композитных компонентов и компонентов из биоматериалов. Построить тонкие горизонтальные слои из 3D моделей, которые разработаны системами автоматизированного проектирования (САПР) и 3D-сканеров – это принцип действия аддитивных установок.

Аддитивное производство состоит из нескольких этапов. Начнем с проектирования в среде САПР. Изготовление любых деталей с использованием АП начинается с создания виртуальной модели с помощью специального программного обеспечения для твердотельного моделирования, которое полностью описывает геометрическую форму и размеры внешней поверхности изделия. На выходе получают трехмерное представление твердого тела или его поверхности.

Далее происходит преобразование в STL-файлы. Программное обеспечение САПР для твердотельного моделирования выводит файлы в формате STL (Stereo Lithography). В файлах описаны внешние замкнутые поверхности изначальной САПР-модели, формирующие основу для расчета слоев.

Перенос STL-файла в машину аддитивного производства и манипулирование этими файлами. STL-файл с описанием изделия передается в машину АП, где производится исправление размеров, позиционирование и ориентация для изготовления изделия.

После переноса файла необходима настройка машины. Перед началом изготовления машину АП необходимо настроить. Устанавливают параметры

изготовления, например пределы использования материала, источник энергии, толщину слоя и т.д.

Этап изготовления. Изготовление изделия представляет собой большей частью автоматизированный процесс, выполняемый практически без контроля оператора.

Далее извлечение изделия. Для извлечения изделия требуется провести некоторые манипуляции с машиной, в которую встроены блокировки безопасности, что обеспечит, например, снижение температуры или отсутствие активно движущихся частей.

После извлечения изделия из машины может потребоваться его дополнительная очистка перед использованием, поэтому данный этап – последующая обработка. На этом этапе изделия могут не иметь нужную прочность или в них остаются вспомогательные поверхности, которые необходимо удалить.

Завершающим этапом аддитивного производства является применение. В некоторых случаях детали не требуют дополнительной обработки и после изготовления и постобработки готовы к использованию. В других случаях может потребоваться грунтовка и покраска для создания нужной текстуры поверхности и финишной обработки.

Сферы применения аддитивных технологий обширны, проектные и производственные предприятия используют аддитивные технологии для изготовления изделий потребительского, промышленного, медицинского, военного назначения и т.д. Именно из-за сокращения времени производства и затрат на него, повышения качества продукции крупные компании стремятся использовать аддитивные технологии.

3D печать все больше влияет на производство продукции, крупные и небольшие предприятия применяют аддитивные технологии для производства готовых изделий. Отрасль постоянно развивается, появляются новые методы, технологии, материалы, прикладные задачи и бизнес-модели.

Библиографический список

1. Гончарова О.Н., Бережной Ю.М., Бессарабов Е.Н., Кадамов Е.А., Гайнутдинов Т.М., Нагопетьян Е.М., Ковина В.М. Аддитивные технологии – динамично развивающееся производство // ИВД. 2016. №4 (43).
2. Зорин В. А., Полухин Е.В. Аддитивные технологии. Перспективы применения аддитивных технологий при производстве дорожно-строительных машин // Строительная техника и технологии. 2016. №3(119). С. 54-57.
3. Шевченко Д.Ю. Аддитивные технологии в машиностроении // Комплексные проблемы развития науки, образования и экономики региона: Научно-практический журнал Коломенского института (филиала) МГМУ (МАМИ). 2015. № 2 (7). С. 89-97.

4. Сироткин О.С. Современное состояние и перспективы развития аддитивных технологий // Авиационная промышленность. 2015. № 2. С. 2225.
5. Смуров И.Ю., Конов С.Г., Котобан Д.В. О внедрении аддитивных технологий и производства в отечественную промышленность // Новости материаловедения. Наука и техника. 2015. № 2. С. 11-22.
6. Литунов С.Н., Слободенюк В.С., Мельников Д.В. Обзор и анализ аддитивных технологий, часть 1 // Омский научный вестник. 2016. № 1 (145). С. 12-17.
7. Волосова М.А., Окунькова А.А., Конов С.Г., Котобан Д.В. Аддитивные технологии: от технического творчества к инновационным промышленным технологиям // Техническое творчество молодежи. 2014. № 5 (87). С. 9-14.

THE EFFECT OF THE SPREAD OF ADDITIVE MANUFACTURING ON THE ENVIRONMENT

Kurushin Daniil S.

State National Research Politechnical University of Perm,
614000, Russia, Perm, Komsomolsky Av. 29,
dan973@yandex.ru

Sholomova Anna I.

State National Research Politechnical University of Perm,
614000, Russia, Perm, Komsomolsky Av. 29,
sholomova1997@mail.ru

This article discusses the technology of additive manufacturing, their process, technology and materials used for the manufacture of parts. The advantages of additive technologies in comparison with traditional production are given. The impact of additive technologies on the environment is considered, the main environmental problems associated with traditional production are identified, namely: huge energy consumption, a large amount of waste materials – the material is used inefficiently, up to 95% of waste can be formed during milling, the impact on the state of air, water and soil – toxic substances formed during production enter the environment, suboptimal model design – excessively heavy and inefficient models, and how additive technologies solve these problems. The main stages of additive manufacturing are also considered.

Key words: additive technologies, ecology, environmental problems, 3D modeling, three-dimensional printing.

ПОВЫШЕНИЕ КАЧЕСТВА ОБУЧАЮЩЕГО МНОЖЕСТВА НЕЙРОННОЙ СЕТИ МЕТОДОМ КЛАСТЕРИЗАЦИИ

Неверов Антон Робертович

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15,
antonneverov.astrohaker@gmail.com

В статье приведены результаты обучения нейросетевой модели на данных с использованием метода кластеризации и без. Описана методика получения наиболее качественного обучения с использованием метода кластеризации. Также было изучено влияние количества кластеров на качество обучения нейросети.

Ключевые слова: искусственный интеллект, нейросетевые технологии, метод кластеризации, обучающее множество.

Введение. При работе с нейросетевыми моделями, неизбежно встает вопрос качества обучающей выборки.

В ходе исследования данного вопроса были проанализированы работы [1-4]. В приведенных выше работах авторы предлагают перед обучением нейронной сети произвести подготовку обучающих данных. Одним из главных этапов такой подготовки предлагается метод кластеризации. В большинстве работ в качестве алгоритма кластеризации выступает метод k -средних, авторы отмечают повышение качества обучения нейронной сети после его применения, но расходятся во мнении сколько элементов должен содержать каждый кластер, а также не дают рекомендаций относительно условий применения этого метода.

В данной работе рассмотрен вопрос применимости метода кластеризации и проведено исследование оптимального количества кластеров в условиях, которые определяются реальной задачей.

Основная часть.

Пусть дано исходное множество, где $X=(X_1, \dots, X_{15})$ – входные параметры, а $Y=\{0|1\}$ – выходной. Всего множество состоит из 671 записей. В качестве нейросетевой модели, которую будем обучать, выступает многослойный персептрон, на входном слое которого 15 нейронов, на скрытом – 2, на выходном – 1. Для проектирования персептрона и его обучения была использована программа «Нейросимулятор 5» [5]. Итоговое множество было разбито на обучающее и тестирующее в пропорции 80% и 20%, т.е. множество для тестирования составило 134 примера. Обучение персептрона проводилось алгоритмом Левенберга-Марквардта, количество итераций – 1000.

Для оценки качества обучения нейронной сети, вычислялась средняя квадратичная ошибка по формуле $MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$, где y_i – фактическое значение, \hat{y}_i – ожидаемое значение i -го тестового примера ($i=1, \dots, N$, N – размер множества), а также поскольку выход имеет бинарное значение будем считать, что если фактическое значение 0, а прогнозируемое меньше 0.5 или если фактическое значение 1 а прогнозируемое больше или равно 0.5, то нейросеть обучалась правильно. Данное условие обучения хорошо видно на диаграммах, представленных ниже.

В качестве алгоритма кластеризации был использован метод сдвига среднего значения (Mean shift) [6] с помощью языка Python и уже реализованного метода Mean shift в библиотеке Scikit-learn [7]. Различное число кластеров получалось благодаря изменению параметра масштабирования в ядре радиальной базисной функции M , применяемой в этом методе кластеризации.

Для начала попробуем обучить нейронную сеть на исходном множестве без кластеризации. Результат показан на рисунке 1.




Рисунок 1. Результат тестирования нейронной сети на исходном множестве

Ошибка MSE составила 0.1004, однако, как видно из рисунка 1, можно наблюдать большую ошибку нейросети в случае, когда выходной параметр равен 1. Так, из 15 примеров, в которых этот параметр задан единичным нейросеть правильно классифицировала только 2 случая. Проанализировав обучающую выборку, можно заметить большое число примеров с выходным параметром равным 0 и малое с 1 в соотношении близким 8:1. Таким образом лишь каждая восьмая запись содержит на выходе единицу, что говорит о большом перекосе обучающей выборки и невозможности качественно обучить нейронную сеть.

Воспользуемся методом кластеризации и применим его лишь для тех записей в обучающем множестве, что содержат в качестве выходного параметра 0.

Применяя метод кластеризации с параметром масштабирования ядра функции M равным 3, получаем 369 кластеров. После повторного обучения нейронной сети на новой обучающей выборке получаем $MSE=0.1013$, однако на диаграмме, представленной на рисунке 2, можно наблюдать только чуть лучший результат. Сеть по-прежнему классифицирует правильный единичный результат только в двух случаях из 15.




Рисунок 2. Результат тестирования нейронной сети, параметр $M=3$

Продолжим увеличивать параметр масштабирования ядра функции, приняв его равным 5. В этом случае мы получаем 222 кластера.

На рисунке 3 приведен результат обучения. $MSE=0,0943$. Заметим, что на диаграмме виден намного более лучший результат при таком числе кластеров, среднеквадратичная ошибка также уменьшилась.




Рисунок 3. Результат тестирования нейронной сети, параметр $M=5$

На рисунке 4 приведен результат обучения с параметром масштабирования ядра функции $M=7$. При этом число кластеров стало 144. $MSE=0.1816$. Наблюдаем опять снижение качества обучения нейросети. Тем не менее, количество правильных единичных классификаций теперь составило 7 из 15.




Рисунок 4. Результат тестирования нейронной сети, параметр $M=7$

При дальнейшем увеличении параметра масштабирования M до 9, количество кластеров снизилось до 102. $MSE=0.2874$. Как видно из рисунка 5, число правильных единичных классификаций теперь составило 13 из 15.



Рисунок 5. Результат тестирования нейронной сети, параметр $M=9$

Таким образом, рассматривая используя различное число кластеров можно добиться большей чувствительность нейронной сети по отношению к

единичным значениям выходного параметра, несмотря на увеличения погрешности MSE.

Заключение. В результате проведения данного исследования было показано, что одним из способов устранения перекоса в обучающем множестве является применение метода кластеризации. Применяя метод кластеризации с различными значениями параметра масштабирования в ядре радиальной базисной функции получаем различное число кластеров. Было показано, что, начиная с какого-то момента, дальнейшее уменьшение числа кластеров ведет к более худшему качеству обучения нейронной сети. Оптимальное значения числа кластеров можно определить, обучая нейронную сеть каждый раз и сравнивая результаты обучения.

Библиографический список

1. Faraoun, Kamel & Boukelif, Aoued. Neural networks learning improvement using the K-means clustering algorithm to detect network intrusions. *International Journal of Computational Intelligence*. 2006. 3. P. 161-168.
2. K.-L. Du. Clustering: A neural network approach. 2010. P. 89-107
3. Гушин К.А., Доленко С.А., Буриков С.А., Доленко Т.А. Применение алгоритмов кластеризации и понижения размерности данных в задачах анализа состава многокомпонентных растворов // XIII всерос. научн. конф. «нейрокомпьютеры и их применение». Тез. докл. м.: мгППУ, 2015. с. 72–73. kohonena-dlya-formirovaniya-preperseptrona (дата обращения: 25.10.2020).
4. Пастухов А.А., Прокофьев А.А. Применение самоорганизующихся карт Кохонена для формирования представительской выборки при обучении многослойного персептрона // Научно-технические ведомости СПбГПУ. Физико-математические науки. 2016. №2(242).
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014
6. Yizong Cheng. Mean Shift, Mode Seeking, and Clustering // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – IEEE, 1995. – Август (т. 17, вып. 8).
7. Scikit-Learn [Электронный ресурс]. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.MeanShift>. (Дата обращения 25.10.2020)

IMPROVING THE QUALITY OF THE TRAINING SET OF THE NEURAL NETWORK BY THE METHOD OF CLUSTERING

Neverov Anton R.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, antonneverov.astrohaker@gmail.com

The article presents the results of training a neural network data model using the clustering method and without. The technique of the highest quality teaching using the clustering method is described. The influence of the number of clusters on the quality of neural network training was also studied.

Key words: artificial intelligence, neural network technologies, clustering method, training set.

УДК 004.032.26

ИССЛЕДОВАНИЕ АЛГОРИТМОВ ВЗАИМОДЕЙСТВУЮЩИХ РОБОТОВ МЕТОДОМ ИМИТАЦИОННОГО МОДЕЛИРОВАНИЯ

*Ушаков Алексей Сергеевич¹, Замятина Елена Борисовна^{1,2},
Ланин Вячеслав Владимирович^{1,2}*

¹ Пермский государственный национальный исследовательский университет, 614990, Россия, г. Пермь, ул. Букирева, 15, e_zamyatina@mail.ru

² Национальный исследовательский университет «Высшая школа экономики», 614070, Россия, г. Пермь, ул. Студенческая, 38, e_zamyatina@mail.ru

В статье рассматриваются вопросы исследования алгоритмов взаимодействующих роботов методами имитационного моделирования. Представлены инструментальные средства для проведения экспериментов, выдвинуты требования к инструментальным средствам для исследования алгоритмов, управляющих роботами. Показана возможность применения этих инструментальных средств.

Ключевые слова: робот, взаимодействие роботов, имитационное моделирование, имитационный эксперимент

В настоящее время роботы стали широко применяться во всех сферах деятельности человека. Если раньше роботы использовались только для замены человека в тяжелой и опасной работе (например, в оборонной, химической, атомной промышленности, при проведении спасательных операций и т.п.), то сейчас они постепенно входят и в обычную, повседневную жизнь человека. Роботы позволяют удовлетворить каждодневные потребности человека: роботы-няньки, уборщики, грузчики, сиделки и т.д. Достоинствами во включении роботов в жизнь человека являются: (а) избавление человека от монотонного, тяжелого и опасного труда; (б) повышение качества выполнения работы; (в) исключение

нежелательного человеческого фактора из факторов, влияющих на качество конечного продукта; (г) сокращение накладных расходов на персонал; (д) повышение производительности в деятельности, которая требует выполнения работ в длительный промежуток времени.

Зачастую для выполнения работ в той или иной области, где используются роботы, возникает необходимость в разработке алгоритмов, по которым роботы действуют. В том случае, если работа выполняется несколькими роботами, возникает необходимость в синхронизации алгоритмов и оптимизации взаимодействия роботов. При этом прежде, чем создать робототехническую систему, целесообразно предварительно оценить ее эффективность, определить, насколько эффективны алгоритмы, по которым осуществляется, в частности, взаимодействие алгоритмов. С этой целью авторы предлагают провести имитационную экспертизу и предлагают рассмотреть инструментальные средства, которые были разработаны на кафедре математического обеспечения вычислительных систем ПГНИУ для того, чтобы оценить эффективность алгоритмов, по которым действуют роботы.

Для построения имитационной модели, и дальнейшей работы с ней, необходимо выбрать конкретный пример.

Рассмотрим роботизированные системы очистки, или просто, роботы-пылесосы [1,2,3]. Роботы-пылесосы осуществляют передвижение и работу в рамках только плоских и горизонтальных поверхностей. Постараемся визуализировать их работу.

Определим некоторые понятия, которые укоренились в рассматриваемой предметной области. Итак, *робот-пылесос* – пылесос, оснащённый искусственным интеллектом (обычный, не мыслящий автомат) и предназначенный для автоматической уборки помещений. В контексте данной работы будет являться исполнителем, или ведомым роботом, который может только выполнять полученные команды и отправлять ответные сообщения, для выполнения алгоритма, по которому робот действует. *Станция* – вспомогательный механизм, осуществляющий зарядку и забор собранной роботами-пылесосами пыли, однако, основным, важным в контексте данной работы, функционалом, будет являться возможность выступать в роли руководителя, или управляющего робота, который получает данные от исполнителей, обрабатывает её в соответствии с определенным алгоритмом и отправляет обратно команды для выполнения. *Тик* – введенная условная единица времени, за которую робот успевает очистить одну клетку. *Поле* – двумерное отображение пространства, на котором действуют роботы-пылесосы. В зависимости от выбранного алгоритма может принимать различный вид. *Ячейка* – элементарная единица поля, на каждой из которых робот-пылесос запрашивает дальнейший алгоритм своих действий у станции. В зависимости от алгоритма, также, как и поле, может иметь различный вид. *Уровень загрязнения* – степень загрязнения отдельной ячейки, задается в процентах (соотв. принимает значения от 0 до 100). *Приемлемый уровень загрязнения* – уровень

загрязнения отдельной ячейки, при достижении которого, дальнейшая обработка этой ячейки не требуется, либо не имеет смысла.

Традиционные исследования, связанные с роботом-пылесосом, сосредоточены на планировании движения и стратегиях построения пути (маршрута). В общем случае, путь генерируется с использованием предварительно запрограммированных шаблонов движения: (а) зигзаг; (б) движение по прямой; (в) движение по спирали; (г) движение вдоль стен; (д) движение комбинированное; (е) по случайной траектории.

Для выполнения навигации робота-пылесоса необходимо собрать данные в режиме реального времени с использованием нескольких видов датчиков (оптических, ультразвуковых, бесконтактных, лазерных, магнитных и т.д.) и камеры. Далее выполняется генерация маршрута робота-пылесоса с использованием данных с сенсоров по специальному алгоритму. Многие исследования были сосредоточены на том, как эффективно подбирать движения робота для каждого цикла очистки. Стратегии для планирования цикла очистки подразделяются на три типа: (а) стратегия с использованием карты, состоящей из ячеек (целевое пространство делится на несколько ячеек, и пути планируются с учетом оценки соседних ячеек с выбором нескольких доступных целевых функций (например, кратчайший путь, путь без препятствий и (или) путь экономии энергии)); (б) стратегия на основе шаблонов (в основе планирования пути используются predetermined соотношения соответствия между сенсорными измерениями и связанными с ними шаблонами); (в) стратегия, основанная на методах искусственного интеллекта (внедряют несколько методов обучения и генерируют адаптивные пути, например, создание адаптивного пути на основе метода градиентного спуска).

Рассмотрим взаимодействие двух роботов, которые используют стратегию работы с помощью шаблона «спираль». В этом случае каждый робот перемещается от периферии поля к его центру и учитывает местоположение второго робота.

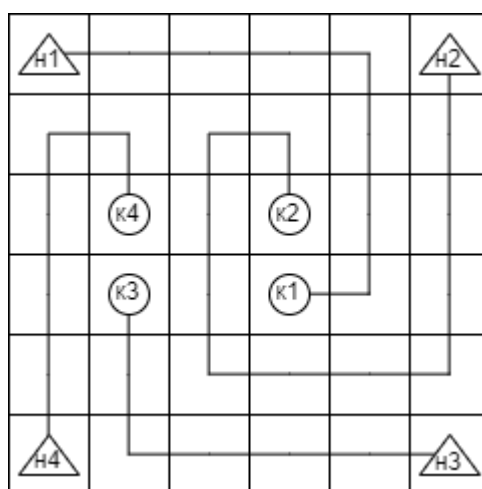


Рисунок 1. Схема перемещения роботов, в соответствии с модифицированным шаблоном «спираль»

Итак, будем работать с системой, предполагающей наличие (а) нескольких роботов-пылесосов, каждый из которых будет оснащен датчиком пыли, (б) станции, выполняющей роль контроллера и берущей на себя основную вычислительную нагрузку, и (в) камеры, позволяющей передавать информацию об очищаемом поле и препятствиях контроллеру.

Структура выбранной авторами робототехнической системы имеет топологию «звезда», где в роли центральной вершины выступает станция, а в роли терминальных вершин – роботы-пылесосы и камера. Представим алгоритм:

Шаг 1. В начале цикла очистки, станция запрашивает информацию о состоянии поля у камеры.

Шаг 2. Станция проверяет, остались ли роботы в активном состоянии (роботы, имеющие возможность для перемещения).

Шаг 2.1. Если все роботы переведены в неактивный режим, то работа считается завершённой.

Шаг 2.2. Иначе, станция запрашивает информацию об актуальном состоянии каждого робота. Если робот активен, то определяются следующие данные: координаты местоположения, направление движения и степень загрязнённости в конкретной ячейке.

Шаг 2.3. Получив информацию от отдельного робота, станция, сверяет уровень загрязнения с допустимым уровнем загрязнения и, тем самым, определяет дальнейшее действие робота:

Шаг 2.3.1. В случае превышения допустимого уровня загрязнения, робот остаётся на месте для дополнительной очистки ячейки.

Шаг 2.3.2. В случае, если уровень загрязнения не превышает допустимый, алгоритм определяет координаты, для перемещения робота, ориентируясь на шаблон перемещения типа «спираль», после чего отправляет их роботу.

Шаг 2.3.3. Если при определении координат для перемещения, оказалось, что все ячейки возле робота заняты (являются путем какого-либо робота, либо стеной), то робот переходит в неактивный режим.

Шаг 3. Получив координаты от станции, робот либо остаётся на месте для дополнительной очистки ячейки, либо передвигается по полученным координатам на соседнюю ячейку.

Шаг 4. После отправки команд каждому роботу, общий счетчик единиц времени (тиков) увеличивается на единицу.

Шаги 2-4 алгоритма последовательно выполняется с до тех пор, пока на очередной итерации не окажется, что все роботы находятся в неактивном режиме, что будет означать окончание уборки заданного поля.

Несмотря на существование методов, концентрирующихся на циклах очистки, существуют методы, позволяющие отказаться от повторения пути при повторных циклах, что позволяет создать новый, более эффективный, алгоритм. Существуют и другие методы, оптимизирующие работу робототехнических систем, они отражены во множестве публикаций.

Один из методов исследования алгоритмов, управляющих роботами, - метод имитационного моделирования.

Исследование алгоритмов взаимодействия роботов будем проводить в среде имитационного моделирования TriadNS [4].

Описание имитационной модели в системе TriadNS можно определить, как $M = (STR, ROUT, MES)$, где STR – слой структур, ROUT – слой рутин, MES – слой сообщений. Слой структур представляет собой совокупность объектов, взаимодействующих друг с другом посредством посылки сообщений. Каждый объект имеет полюсы (входные и выходные), которые служат соответственно для приема и передачи сообщений. Основа представления слоя структур – графы. В качестве вершин графа следует рассматривать отдельные объекты. Дуги графа определяют связи между объектами. Объекты действуют по определенному алгоритму поведения, который описывают с помощью рутины. Рутинa представляет собой последовательность событий, планирующих друг друга. Выполнение события сопровождается изменением состояния объекта. Состояние объекта определяется значениями переменных рутины. Таким образом, система имитации является событийно-ориентированной. Рутинa так же, как и объект, имеет входные и выходные полюса. Входные полюса служат соответственно для приема сообщений, выходные полюса – для их передачи. Совокупность рутин определяет слой рутин ROUT. Слой сообщений (MES) предназначен для описания сообщений сложной структуры.

Для сбора, обработки и анализа имитационных моделей в системе TriadNS существуют специальные объекты – информационные процедуры и условия моделирования, которые реализуют алгоритм исследования модели.

Для исследования алгоритмов взаимодействия роботов в TriadNS необходимо разработать подклассы в базовой онтологии TriadNS. Они представлены на рис.2.

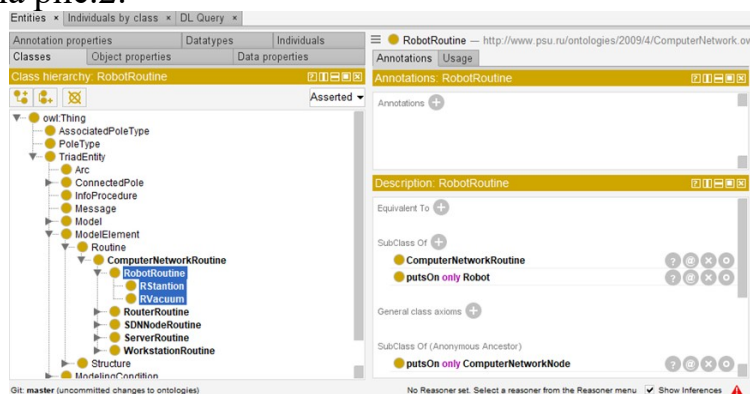
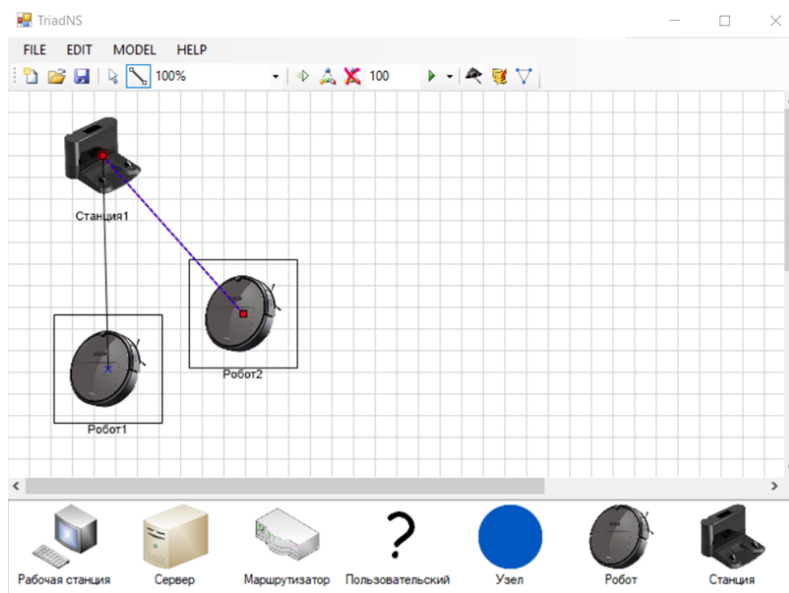


Рисунок 2. Подклассы объектов робототехнической системы

На рис.3. представлена исследуемая система роботов в системе имитационного моделирования TriadNS.



**Рисунок 3. Робототехническая система.
Графический интерфейс в TriadNS**

Для проведения исследования используют инструментарий информационных процедур. При проведении экспериментов будем использовать следующие параметры: (а) размер рабочего поля; (б) степень загрязненности рабочего поля; (в) количество активных роботов в сети; (г) «мощность» роботов в сети.

Модель была запущена на каждом из наборов данных по 10 раз, в качестве конечного результата, на графиках ниже, используется среднее значение.

На рисунке 4. представлен график, показывающий как зависит время работы системы (количество единиц времени) от размера рабочего поля. При проведении эксперимента использовалась сеть с одной станцией, имеющей приемлемый уровень загрязнения, равный 10%, и двумя активными роботами, имеющими мощность 30%.




Рисунок 4. Зависимость времени обработки поля от его размеров




Рисунок 4. Зависимость времени обработки поля от мощности пылесосов

Заключение. Построена имитационная модель робототехнической системы, включающей станцию и двух роботов. Проведены эксперименты в среде имитационного моделирования TriadNS. Эксперименты показали, что алгоритмы, которые управляют роботами могут быть успешно исследованы методами имитационного моделирования, т.е. прежде, чем исследовать построенные робототехнические системы, актуальные в настоящее время, целесообразно провести имитационную экспертизу. Система имитационного моделирования TriadNS доказала свою жизнеспособность к проведению экспериментов и получению необходимых для исследователей результатов в области робототехники и возможность быстрой настройки на конкретную предметную область. Авторы предполагают исследовать более сложные робототехнические системы и алгоритмы, управляющие ими.

Благодарность. Работа выполнена при финансовой поддержке РФФИ и Администрации Краснодарского края в рамках научного проекта № 19-47-230003.

Библиографический список

1. Lee H., Banerjee A. Intelligent scheduling and motion control for household vacuum cleaning robot system using simulation based optimization Proceedings of the 2015 Winter Simulation Conference. Yilmaz L., Chan W. K. V., Moon I., Roeder T. M. K., Macal C., and Rossetti M. D eds., 2015. – pp. 1163-1171.
2. Myung H., Jeon, H. and Jeong, W. Virtual Door Algorithm for Coverage Path Planning of Mobile Robot.” Proceedings of IEEE International Symposium on Industrial Electronics, Seoul, Korea. pp. 658-663.
3. Oh, J., Choi, Y., Park, J. and Zheng, Y. F. 2004. “Complete Coverage Navigation of Cleaning Robots using Triangular-Cell-Based Map.” IEEE Transactions on Industrial Electronics 51(3):718-726.
4. Замятина Е. Б., Миков А. И., Михеев Р. А. Лингвистические и интеллектуальные инструментальные средства симулятора

RESEARCH OF ALGORITHMS OF INTERACTING ROBOTS BY THE SIMULATION METHOD

Ushakov A.S.¹, Zamyatina E.B.^{1,2}, Lanin V.V.^{1,2}

¹Perm State University,

Str. Bukireva, 15, Perm, Russia, 614990, e_zamyatina@mail.ru

²National Research University “Higher School of Economics”,

Str. Studencheskaya, 38, Perm, Russia, 614070, e_zamyatina@mail.ru

The paper deals with the research of algorithms for interacting robots using simulation methods. Software tools for conducting experiments are presented. Authors consider requirements for software tools needing for researching algorithms that control robots. The possibility of using these tools is shown.

Keywords: robot, robot interaction, simulation, simulation experiment

УДК 316.32

РИСКИ ЦИФРОВИЗАЦИИ И РОБОТИЗАЦИИ ДЛЯ СФЕРЫ СОЦИАЛЬНОЙ ЗАЩИТЫ И СОЦИАЛЬНОГО ОБСЛУЖИВАНИЯ В РОССИИ

Гасумова Светлана Евгеньевна

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, svetagasumova@ya.ru

Рассматривается становление научных взглядов на риски цифровизации и роботизации в сфере социальной защиты и социального обслуживания в России. Предлагается авторская классификация таких рисков. Описан риск внедрения неэффективных программных средств в деятельность сотрудников органов социальной защиты и социальных служб, неоправданно увеличивающих нагрузку на персонал и не позволяющих тратить достаточное время на общение с получателями услуг и оказание им непосредственной помощи. Проанализирован риск создания и внедрения онлайн-сервисов для граждан на основе недостоверной, некорректной, не ориентированной на целевую аудиторию либо научно не обоснованной информации, способной причинить вред ее потребителю, усугубить трудную жизненную ситуацию. Выделены также риск сокращения рабочих мест в системе социальной защиты и социального обслуживания вследствие цифровизации и роботизации и риск причинения вреда получателям мер социальной защиты и социальных услуг вследствие использования не

достаточно апробированной робототехники (например, роботов-сиделок). Описан риск снижения качества социальных услуг, переведенных в форму электронного сервиса, предоставляющегося с использованием дистанционных форм работы, а также риск отсутствия возможности у части населения получать социальные услуги в электронной форме.

Ключевые слова: цифровизация, роботизация, искусственный интеллект, социальная защита, социальное обслуживание.

Может ли сфера социальной защиты и социального обслуживания, напрямую связанная с формированием социального благополучия в российском обществе, пострадать в результате не достаточно продуманной цифровизации и роботизации? Попробуем ответить на этот вопрос.

В отечественных исследованиях подобной проблематике пока уделяется не достаточно внимания. Большинство работ посвящены социально-экономическим аспектам (можно даже сказать – социально-экономическим эффектам) цифровизации в сфере социальной защиты (А.В. Яковенко [1], О.В. Андреева, А.А. Суховеева [2], В.А. Арутюнян, Е.Э. Путинцева, А.Р. Шахова, А.И. Швейкина [3], О.М. Комарова [4], Н.А. Симченко, И.А. Троян, М.В. Горячих, Е.С. Андрющенко [5], А.С. Бихдрикер, Т.В. Лисицына [6]), и значительно реже – в сфере социального обслуживания (Т.И. Худякова [7], А.С. Андрияшкина, Р.Ю. Ванцев [8], А.Х. Маликова [9] и др.). Как правило, авторы обосновывают необходимость внедрения цифровых технологий, характеризуют подобный успешный опыт определенного региона и прогнозируют пользу в результате данных преобразований, практически не оценивая их риски. Рискообразующие факторы предметно рассматриваются разве что у И.Я. Богданова [10] с позиции управленческой концепции для обеспечения надежной социальной защиты государства в условиях цифровой экономики.

Между тем, по мнению Козыревой Л.Д. и О.В. Шкурупей [11], при всех «плюсах» цифровизации (снижение стоимости социальных услуг, повышение доступности, качества и конкурентоспособности), она приведет и к целому ряду «вызовов», на которые в силу ослабления традиционных институтов адаптации придется отвечать социальной сфере. Авторы убеждены, что процесс цифровизации в глобальном и локальном масштабе в перспективе приведет к увеличению количества потребителей и необходимости повышения качества и разнообразия социальных услуг.

Как справедливо отмечают А. Грунвальд, В.Н. Железняк и Е.В. Середкина, «метод проб и ошибок в обществе «подрывных инноваций» (disruptive innovation) недопустим и безответствен» [12, с. 44]. Они рассуждают о всегда проявляющейся связи инновационного технологического развития (при всех его однозначных экономических и социальных выгодах) с рисками и ставят этический вопрос о том, при каких условиях принятие риска может быть оправданным. Авторы приходят к выводу, что управление неизбежными рисками должно осуществляться

максимально ответственным образом, на основе адекватного и тщательного их обсуждения.

Так, интерпретируя их подход, прежде, чем внедрять инновационную цифровую технологию в сферу социальной защиты и социального обслуживания, необходимо ответить на следующие вопросы:

1. Кому может быть нанесен ущерб, какие социальные группы могут подвергнуться опасности?

2. Какие именно потенциальные риски грозят различным социальным группам?

3. Кто (какой орган власти) принимает решения в этой сфере, может контролировать ситуацию и будет должен нести ответственность?

4. Какова вероятность возникновения выделенных рисков?

5. Каков пространственный и временной масштаб рисков?

6. Существуют ли какие-либо косвенные риски, например, системные эффекты?

7. Что нужно предпринять в экстренных ситуациях?

Итак, риски цифровизации и роботизации, безусловно, есть в любой сфере. В системе социальной защиты и социального обслуживания к ним, на наш взгляд, можно отнести следующие.

Во-первых, это риск внедрения неэффективных программных средств в деятельность сотрудников органов социальной защиты и социальных служб, неоправданно увеличивающих нагрузку на персонал и не позволяющих тратить достаточное время на общение с получателями услуг и оказание им непосредственной помощи.

Проведенное нами в 2019 г. интервью с руководителями 18 социальных служб в Пермском крае показало, что сегодня необходима разработка новых цифровых технологий, которые существенным образом повысят качество работы и облегчат труд сотрудников. Почти половина опрошенных руководителей социальных служб придерживаются мнения, что, к сожалению, пока имеющиеся информационные технологии не столько помогают в работе, сколько увеличивают нагрузку на персонал. Примерно 30% рабочего времени тратится только на заполнение данных в АИС. По мнению западных аналитиков M. Aldridge, W. Macy и T. Walz, необходимость тратить значительное время на заполнение баз данных может способствовать развитию у социальных работников «бюроневроза» [13, р. 23-36.]. Кроме того, это то время, которое специалисты могли бы потратить на общение с клиентами, обратившимися за помощью. На наш взгляд, должны быть созданы такие автоматизированные информационные системы, введение данных в которые занимает не более 10% рабочего времени. Например, это возможно достичь за счет готовых шаблонов для автозаполнения в большинстве полей, благодаря чему специалист мог бы за секунды просто выбрать нужные варианты заполнения информации о клиенте либо оказанной услуге. Либо в идеале это может быть даже голосовой ввод информации.

У половины участвовавших в исследовании поставщиков социальных услуг деятельность еще не полностью автоматизирована. В большей части организаций (10 из 18) используемая информационная система, несмотря на ее положительную оценку, нуждается в совершенствовании и доработке. Это четко свидетельствует о потребности в дальнейшем развитии автоматизации в сфере социального обслуживания населения. Но специфика социальных служб такова, что новые информационные технологии для использования в этой сфере должны выбираться и внедряться крайне осторожно. Это должны быть такие технологии, которые действительно облегчают труд специалистов по социальной работе, а не создают дополнительную нагрузку и не отнимают большое количество времени.

Во-вторых, это риск создания и внедрения онлайн-сервисов для граждан на основе недостоверной, некорректной, не ориентированной на целевую аудиторию либо научно не обоснованной информации, способной причинить вред ее потребителю, усугубить трудную жизненную ситуацию.

Информация о пособиях, льготах, субсидиях, компенсациях, порядке получения социальных услуг очень быстро устаревает, поскольку законодательство в этой сфере стремительно меняется. Справочные онлайн-сервисы по подбору льгот и социальных услуг, с одной стороны, очень нужны населению (как показали проведенные нами опрос 1050 участников сообщества ВКонтакте «Детские пособия в Перми и крае» и интервью с его руководителем в 2020 г.), но с другой стороны, нужно понимать, что для поддержания таких онлайн-сервисов в актуальном состоянии нужна целая команда сотрудников. Даже сегодня распространение недостоверной информации по вопросам социальной защиты в неформальных сообществах в социальных сетях ведет к конфликтным ситуациям, недоверию граждан к органам социальной защиты. Более того, этим намеренно пользуются мошенники, предоставляя в отсутствие официальных справочных онлайн-сервисов гражданам платно консультации с заведомо ложными сведениями и вынуждая их затем, таким образом, оплачивать еще и обращение в суд из-за якобы нарушенных прав [14].

В-третьих, можно прогнозировать риск сокращения рабочих мест в системе социальной защиты и социального обслуживания вследствие цифровизации и роботизации.

Дело в том, что Правительство Российской Федерации уже сегодня принимает меры, которые явно могут привести к полной автоматизации деятельности специалистов системы социальной защиты и отсутствию необходимости в труде большинства из них. В рамках реализующегося в России федерального проекта «Цифровое государственное управление» национальной программы «Цифровая экономика Российской Федерации» проводятся мероприятия по направлению «Цифровая трансформация государственных и муниципальных услуг», нацеленные на их оптимизацию. Уже провозглашен запрет на запрос у граждан информации, которая имеется в распоряжении государства: все необходимые документы должны запрашиваться из электронных реестров органов власти. Введен принцип

комплексного подхода к решению жизненных ситуаций заявителей посредством суперсервисов и минимизация участия чиновников в принятии решений по оказанию услуг, перевод услуг в режим online. Предусмотрена омниканальность взаимодействия с использованием любых удобных пользователю инструментов обращения за услугами (мобильные устройства, соцсети, сайты, банковские приложения, email). проактивное предоставление услуг на основании изменения статусов граждан в ведомственных реестрах. Еще одним принципом является исключение бумажных носителей в процессах оказания услуг, межведомственного взаимодействия и документооборота между органами власти [15]. В результате необходимость личного приема граждан в органах социальной защиты, очевидно, отпадет в ближайшее время.

Профессор МГИМО В.С. Осипов уверен в том, что самый главный риск для рынка труда – это алгоритмизация: исчезнут те виды деятельности, которые можно описать алгоритмами. А научный сотрудник Центра анализа компетенций и стандартов РАНХиГС А.А. Коваль привела данные о том, что в результате цифровизации экономики до 14% рабочих мест могут быть автоматизированы. Более того, проведенные академией исследования показали, что 6 из 10 человек уже сейчас не отвечают требованиям цифровой экономики [16]. Однако, по мнению директора Института проблем рынка РАН В.А. Цветкова, «цифровая безработица» – это естественный процесс, и он не несет серьезных угроз. По его мнению, думать сегодня надо не о том, как сохранить малоэффективные рабочие места, которые уже не соответствуют новому уровню развития производительных сил, а о том, как создать условия для подготовки новых специалистов, которых сегодня просто не хватает, а через десять лет будет уже катастрофически не хватать [16].

Затем на социальную сферу может широко распространиться роботизация. Пока наиболее высок интерес к замене сотрудников на роботов, как показали результаты исследования «Делойта» в СНГ, у банков и финансовых институтов, розничной и оптовой торговли, в энергетике и добывающей промышленности. Роботизация все чаще входит в элементы стратегии компаний для автоматизации монотонных задач, сокращения издержек и минимизации ошибок, возникающих из-за влияния человеческого фактора. Поэтому 63% представителей российского бизнеса уже готовы ее провести [17]. В сфере социальной защиты и социального обслуживания отличными задачами для роботизации являются действия, связанные с заполнением форм, а также с занесением и переносом данных в различные системы.

Уже сегодня, согласно данным международного исследования холдинга «Ромир» и сообщества компаний GlobalNR (2020 г.), 20% россиян допускают вероятность того, что в ближайшие 5 лет их работу вместо них начнет выполнять робот или компьютер. Любопытно, что среди жителей десяти ведущих стран мира (Бразилии, Великобритании, Германии, Индии, Италии, Китая, России, США, Таиланда, Южной Кореи) этот показатель в

среднем составляет 29%, при этом угрозу остаться безработным из-за роботизации чаще видят жители стран, где роботов практически не используют. Чаще других заявляли о ней жители Индии (61%). В странах, которые уже шагнули вперед (Германии, США, России, Великобритании с показателем 20%), хорошо понимают, что никакой искусственный интеллект не сможет полностью заменить человека. Как комментирует эту ситуацию президент исследовательского холдинга «Ромир», доктор социологических наук А.В. Милехин: «Будущее за человекоцентричной системой, робот – лишь средство улучшения качества жизни» [18].

Исследования показывают, что роботизация будет, скорее всего, негативно воспринята работниками, ведь они нередко полагают, что роботы полностью заменят человека. Это выливается в неприятие технологии и отрицание ее полезности. На практике данное отрицание может выражаться в саботаже при проработке вопросов, связанных с автоматизацией процессов. Руководители могут повышать уровень мотивации своих работников к процессу роботизации путем переориентирования с рутинных задач на более интеллектуальные, а также путем обучения их новым навыкам, которые будут востребованы в ближайшем будущем. Среди эффектов от внедрения роботизации респонденты «Делойта» отдают первые места увеличению скорости выполнения задач (71%), автоматизации монотонных процессов (70%), снижению затрат (69%) и снижению рисков и ошибок при выполнении задач (68%). 53% опрошенных работодателей в России (и 66% в мире) считают, что основным следствием автоматизации в ближайшие три года станет переквалификация существующих сотрудников [17].

Пока кажется фантастичным, что органы социальной защиты или поставщики социальных услуг начнут закупать роботов-андроидов, но опыт сферы бизнеса показал, что средний период окупаемости среди компаний, которые внедрили роботизацию, составляет всего один-два года [17]. То есть экономически это довольно выгодно.

В-четвертых, существует риск причинения вреда получателям мер социальной защиты и социальных услуг вследствие использования не достаточно апробированной робототехники.

Создание и массовое использование робота-сиделки – самое очевидное и необходимое, что может произойти в сфере роботизации социальных услуг. Но в случае поломки такого робота, сбоя или ошибки в его программном обеспечении он может нанести травмы человеку (например, слишком сильно сжав человеческое тело).

Е.В. Середкина, О.А. Бурова, И.И. Безукладников [19] и Е.Н. Ядова [20] анализируя готовность российского общества взаимодействовать с искусственным интеллектом и роботами, приводят данные опроса пожилых людей в Пермском крае о том, согласились бы они, чтобы в случае необходимости (при ухудшении состояния их здоровья и снижении способности к самообслуживанию) уход за ними осуществлял не живой человек, а сервисный робот-андроид. Поразительно, что около 40% представителей старшего поколения согласны на это, аргументируя, правда,

свою готовность взаимодействовать с роботом не желанием приобщиться к новым технологиям, а целью не зависеть от родственников или сиделки, не причинять кому-либо неудобств.

Заметим, что попытки создать андроидов-сиделок ведутся еще с нулевых годов. В 2008 г. была представлена японская разработка Лаборатории разумной робототехники Осацкого университета совместно с отделом аниматроники компании «Кокоро» (Kokoro Company Ltd) – геноид Repliee с внешностью японской пятилетней девочки (см. рис. 1). Он предназначен для ухода за пожилыми и недееспособными людьми: оказания помощи в поиске вещей, передвижении, а также для поддержания беседы и развлечения [21]. В ближайшее время робототехника, очевидно, будет стремительно совершенствоваться и станет более доступной для социального использования.




Рисунок 1. Робот-андроид Repliee, предназначенный для ухода за пожилыми и недееспособными людьми [21]

В-пятых, можно выделить риск снижения качества социальных услуг, переведенных в форму электронного сервиса, предоставляющегося online с использованием дистанционных форм взаимодействия. Например, психологическая помощь, оказываемая сотрудником социальной службы в режиме видеоконференции, при всем таланте психолога может не быть настолько эффективной, как это было бы при очном консультировании, из-за ограничений, которые несут электронные коммуникации.

При этом перевод в электронную форму процедуры предоставления мер социальной защиты, напротив, позволит расширить охват населения и предоставлять помощь в проактивном режиме, более эффективно. То есть граждане вообще не должны будут сами обращаться в органы власти, а различные денежные выплаты будут назначаться автоматически, с момента присвоения гражданину определенного социального статуса (например, инвалид), автоматизированной системой, без участия специалиста. Человеку будет просто приходиться push-уведомление об этом.

И, наконец, *в-шестых*, на современном этапе социально-экономического развития российского общества, в условиях сохраняющегося информационного неравенства, есть риск отсутствия доступа у части

населения (прежде всего – пожилых людей) к цифровым технологиям, а значит – риск их «социально-цифровой депривации», то есть ограничения в удовлетворении потребностей в использовании социальных цифровых сервисов и связанного с этим снижения качества жизни. В силу отсутствия знаний и умений пользоваться Интернетом, они вообще не смогут обратиться за цифровыми социальными услугами.

В заключение отметим, что цифровизация и роботизация, безусловно, несут, в первую очередь, позитивные последствия для сферы социальной защиты и социального обслуживания. Среди них, как справедливо отмечает А.А. Шабалкина [22, с. 60], – появление новых, связанных с цифровизацией, высокооплачиваемых рабочих мест; повышение мобильности работников за счет методов удаленной работы; улучшение трудоспособности работника за счет новых технических устройств типа экзоскелетов, помогающих поднимать тяжести (например, в надомном социальном обслуживании), либо использования так называемых коботов – роботов, способных к кооперации с человеком для выполнения вспомогательной работы.

Главное сегодня – провести научный анализ и описать возможные абстрактные риски таким образом, чтобы они стали четко дифференцируемыми и идентифицируемыми. Только когда появятся точные описывающие формулировки, станет возможна их правовая оценка, нормативное регулирование и разработка мер по предотвращению либо снижению таких рисков.

Библиографический список

1. Яковенко А.В. Социальная защита населения в условиях цифровизации общества: проблемные аспекты // Социальная работа: современные проблемы и технологии. 2020. № 1. С. 230-237.
2. Андреева О.В., Суховеева А.А. Цифровизация как инструмент социально-экономического развития (на примере системы социальной защиты граждан) // Технологические инициативы в достижении целей устойчивого развития: матер. междунар. науч.-практ. конф. XV Южно-Российский логистический форум. Ростов-на-Дону, 2019. С. 191-195.
3. Арутюнян В.А., Путинцева Е.Э., Шахова А.Р., Швейкина А.И. Цифровая экономика на службе общества: новые формы социальной защиты населения // Матер. Междунар. студ. науч.-практ. форума по финансовой грамотности / Волгоградский гос. ун-т. Курск, 2018. С. 320-328.
4. Комарова О.М. Развитие социальной сферы в условиях цифровой экономики // Инновационное развитие социально-экономических систем: условия, возможности: матер. VII Междунар. науч.-практ. конф. Орехово-Зуево, 2019. С. 57-61.
5. Симченко Н.А., Троян И.А., Горячих М.В., Андрищенко Е.С. Цифровизация социально значимых услуг в условиях цифровой трансформации экономики республики Крым // Сервис в России и за рубежом. 2019. Т. 13. № 2 (84). С. 223-234.

6. Бихдрикер А.С., Лисицына Т.В. Информационное обеспечение управления сферой социальной защиты населения в регионе // Социальная работа: современные проблемы и технологии. 2020. № 1. С. 30-37.
7. Худякова Т.И. Цифровизация социальных услуг в России // Интеллектуальные системы управления в цифровой экономике: сб. мат. Форум молодых ученых. Под ред. О.Н. Пронской. Курск, 2020. С. 245-248.
8. Андрияшкина А.С., Ванцев Р.Ю. Совершенствование предоставления гражданам мер социальной защиты в условиях цифровизации социальной сферы // Цифровая парадигма развития общества: взгляд из будущего: сб. науч. тр. по итогам студ. науч.-практ. конф. Редколлегия: Н.С. Яшин и др. Саратов, 2019. С. 85-87.
9. Маликова А.Х. Цифровизация как мера по повышению эффективности предоставления социальных услуг // Актуальные проблемы развития правовой системы в цифровую эпоху: матер. Междунар. юр. науч. симпозиума. Отв. ред. С.П. Бортников. Самара, 2019. С. 62-64.
10. Богданов И.Я. Цифровая экономика и ее риски в социальной защите общества // ЦИТИСЭ. 2019. № 5 (22). С. 7-14.
11. Козырева Л.Д., Шкурупей О.В. Система социального обслуживания населения в эпоху цифровизации: социальные инновации и перспективы развития // Научные труды Северо-Западного института управления РАНХиГС. 2018. Т. 9. № 4 (36). С. 184-189.
12. Грунвальд А., Железняк В.Н., Середкина Е.В. Беспилотный автомобиль в свете социальной оценки техники // Технологос. 2019. № 2. С. 41-51.
13. Aldridge M., Masy W., Walz T. Beyond management: Humanizing the administrative process. Iowa City: University of Iowa School of Social Work, 1982.
14. Тетерина А.А. Проблемы и перспективы информационной открытости системы социальной защиты в Пермском крае // Социальная безопасность и защита человека в условиях новой общественной реальности: современные механизмы преодоления бедности: матер. XI Междунар. науч.-практ. конф. ученых, преподавателей, специалистов, аспирантов. Пермь, 2019. С. 94-98.
15. Суперсервисы и цифровая трансформация госуслуг // Министерство цифрового развития, связи и массовых коммуникаций Российской Федерации [Электронный ресурс] URL: <https://digital.gov.ru/ru/activity/directions/854/> (дата обращения: 10.10.2020).
16. Скопинцева Е. Половина профессий исчезнет из-за роботизации // Экономика и жизнь. 2019. №48 (9814) [Электронный ресурс] URL: <https://www.eg-online.ru/article/412384/> (дата обращения: 10.10.2020).
17. Кононов И. Бизнес-рутину повесить на роботов // Экономика и жизнь. 2020. №10 (9826) [Электронный ресурс] URL: <https://www.eg-online.ru/article/416098/> (дата обращения: 10.10.2020).

18. 20% россиян согласны, что через пять лет их работу будут выполнять роботы или компьютеры // Экономика и жизнь. 2020. 10 июля [Электронный ресурс] URL: <https://www.eg-online.ru/news/423508/> (дата обращения: 10.10.2020).
19. Середкина Е.В., Бурова О.А., Безукладников И.И. Готово ли общество взаимодействовать с искусственным интеллектом и роботами? (Анализ результатов анкетирования в России и Японии) // Социально-гуманитарные знания. 2018. № 10. С. 109-114.
20. Середкина Е.В., Безукладников И.И., Ядова Е.Н. Взаимодействие человека и робота: социально-гуманитарная экспертиза // Социально-гуманитарные знания. 2019. № 10. С. 102-108.
21. Repliee – линейка женских роботов-андроидов // Новости технологий. 2008. 12 окт. [Электронный ресурс] URL: <http://techvesti.ru/node/491> (дата обращения: 10.10.2020).
22. Шабалкина А.А. Влияние цифровой революции на изменение рынка труда и требования к человеческому капиталу // World science: problems and innovations: сборник статей XIV Международной научно-практической конференции: в 2 частях. Часть 2. Пенза, 2017. С. 59-62.

RISKS OF DIGITALIZATION AND ROBOTIZATION FOR SOCIAL WELFARE AND SOCIAL SERVICE IN RUSSIA

Gasumova Svetlana E.

Perm State University, 614990, Russia, Perm, st. Bukireva, 15,
svetagasumova@ya.ru

We consider the formation of scientific views on the risks of digitalization and robotization in the field of social welfare and social services in Russia. The author's classification of such risks is proposed. We describe the risk of introducing ineffective software tools into the activities of employees of social agencies and social services, unjustifiably increasing the workload on staff and not allowing them to spend sufficient time communicating with service recipients and providing them with direct assistance. The risk of creating and implementing online services for citizens on the basis of inaccurate, incorrect, not targeted at the target audience or scientifically unsubstantiated information that can harm its consumer and aggravate a difficult life situation has been analyzed. The risk of job cuts in the social welfare and social services system due to digitalization and robotization and the risk of harm to recipients of social support measures and social services due to the use of insufficiently tested robotics (for example, robotic nurses) are also highlighted. The risk of a decrease in the quality of social services converted into an electronic service provided using remote forms of work, as well as the risk of the inability of a part of the population to receive social services in electronic form, is described.

Key words: digitalization, robotization, artificial intelligence, social welfare, social services.

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ СТОИМОСТИ КВАРТИР МОСКВЫ

Мелентьева Александра Евгеньевна

Национальный исследовательский университет «Высшая школа экономики»
Факультет городского и регионального развития,
101000, Москва, ул. Мясницкая, д.13, стр. 4. amelentieva20@gmail.com

В статье приведены результаты проектирования и разработки системы оценки стоимости квартир города Москвы. При прогнозировании стоимости система учитывает факторы, включающие характеристики квартиры и дома, в котором располагается квартира. Методом сценарного прогнозирования построены зависимости стоимости квартир от площади, этажа, наличия и количества лифтов в доме, высоты потолка.

Ключевые слова: искусственный интеллект, нейросетевые технологии, рынок квартир, оценка стоимости, прогнозирование, жилая недвижимость.

Введение. Стоимость недвижимости является актуальным вопросом в экономической и бытовой сфере. Целью данного исследования является определение значимости параметров, влияющих на стоимость недвижимости в городе Москве и определение возможности прогнозирования стоимости на основе факторов доступных из открытого источника – базы данных о недвижимости «Циан». В качестве гипотезы рассматривается, что на стоимость квартиры оказывают влияние 15 факторов. Более всего оказывают влияние площадь квартиры и удаленность от метро.

При создании модели оценки жилой недвижимости города Москвы, в качестве входных параметров были включены факторы, включающие:

X1 — общую площадь квартиры,

X 2 — этаж (от 1 до 51)

X 3 — количество этажей в доме (от 2 до 67),

X 4 — наличие и количество пассажирских лифтов в доме (от 0 до 4),

X 5 — наличие и количество грузовых лифтов в доме (от 0 до 3)

X 6 — год строительства (от 1910 до 2020 года),

X 7 — наличие мусоропровода (нет - 0; есть - 1),

X 8 — тип парковки (нет - 0; наземная - 1; подземная - 2),

X 9 — количество комнат (от 1 до 6),

X 10 — тип дома (нет данных - 0; панельный - 1; кирпичный - 2; монолитно-кирпичный - 3; монолитный - 4.),

X 11 — высота потолков (от 2 до 3,7 метров),

X 12 — количество санузлов (от 0 до 2х),

X13 — наличие и тип ремонта (без ремонта - 0; косметический - 1; евроремонт – 2, дизайнерский - 3.),
X14 — вид из окна (на улицу - 0; во двор - 1; на улицу и двор - 2), x15 — расстояние до метро (от 0 до 20 км).

Для обучения нейронной сети было сформировано множество на основе значений факторов, собранных с базы данных объявлений о недвижимости Циан от октября 2019 года.

Оптимальное количество примеров обучающего множество вычислялось по формуле $7N_x+15$, N_x – число входных параметров (в данном случае 15). То есть для получения релевантных результатов размер обучающего множества должен составлять не менее 120 примеров.

Совокупность примеров была разбита на обучающее множество, состоящее из 130 примеров и тестирующее множество, состоящее из 15 примеров. Рекомендуемый размер тестирующего множества должен составлять 10-15% от обучающего. В данном случае размер тестирующего множества составляет 11,5%, что укладывается в рекомендуемый диапазон. Обучающее множество использовалось для обучения нейросети. Проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью выполнялись с помощью нейропакета «Нейросимулятор 5.10» [1] по методике, сложившейся в Пермской научной школе искусственного интеллекта.

Оптимальная структура данной нейросети [2] имеет вид персептрона и состоит из 19 нейронов, имеет 48 связей. Среди них 1 скрытый слой с 3-мя нейронами, 15 входных нейронов и 1 выходной нейрон. Функция активации нейронов выходного слоя имеет линейный вид.




Рисунок 1. Нейронная сеть – персептрон с пятнадцатью входными нейронами, одним выходным нейроном и тремя нейронами скрытого слоя

В процессе обучения ошибка обучения опустилась до значения 0,086, а ошибка тестирования опускалась до 0,5.

Данные о параметрах квартир тестового множества не были использованы при обучении нейронной сети. Для нейросети они являются новыми и на них тестируются ее прогностические свойства.

Погрешность на обучающем множестве:

Выход	Средн. кв. отн. (%)	Средн. отн. (%)	№ примера с макс. ош
Y1	1.467	0.9817	11

Погрешность на тестируемом множестве:

Выход	Средн. кв. отн. (%)	Средн. отн. (%)	№ примера с макс. ош
Y1	16.8547	13.7432	10

С помощью нейростимулятора определена значимость каждого из факторов, оказывающих влияние на стоимость квартиры. Наиболее важна площадь квартиры (№1), ее значимость составляет около 70%. Это объясняется тем, что между стоимостью квартиры и стоимостью ее квадратного метра наблюдается прямая зависимость, которая и закладывается в алгоритм нейросети.

Значимость других 14 факторов не превышает 1%. Из них заметно влияние фактора «Наличие и количество пассажирских лифтов в доме» (№4 - 0,07%), что можно объяснить тем, что в малоэтажном домостроении и старом фонде часто отсутствует лифт, что ограничивает в комфорте использования недвижимости маломобильные группы населения и пользователей с детьми, что в свою очередь снижает группу потенциальных покупателей и снижает стоимость квартиры. Также значимость фактора «Высота потолков» (№11 - 0,06%) по той же причине. В старом фонде в большинстве своем потолок низкий, что оказывает влияние на стоимость квартиры.




Рисунок 2. График обучения проектируемой нейросети

Значимость факторов




Рисунок 3. Значимость входных параметров, вычисленная с помощью нейросети

Для выявления характерных закономерностей было проведено исследование зависимости стоимости квартиры от высоты потолка, количества лифтов и площади. Для этого были созданы дополнительные множества на основе данных по 3-м типовым квартирам из тестируемого множества [3]. Данные были скорректированы таким образом, что все факторы кроме исследуемого оставались неизменными. Результаты были визуализированы в виде графиков [4].




Рисунок 4. График зависимости стоимости квартиры от высоты потолка

График зависимости стоимости квартиры от высот потолка показывает, что для 1-комнатной квартиры наблюдается прямая зависимость в форме гиперболы, то есть при увеличении высоты потолка стоимость квартиры растет. При изменении высоты потолка от 2,5 для 3,5 метров стоимость

растет постепенно, а затем наблюдается резкий рост. Это объясняется тем, что при высоте потолка выше 3,5 метров из квартиры с небольшой площадью можно сделать двухуровневую квартиру, значительно увеличив площадь пола, что и показывает представленный график. Однако фактически площадь квартиры остается небольшой согласно данным застройщика и обмерам БТИ. График зависимости 2-комнатной квартиры имеет схожие тенденции. График 3-комнатной квартиры имеет отличительную динамику. При увеличении высота потолка стоимость, наоборот, снижается и только после 3,5 метров растет.

График зависимости стоимости квартиры от количества лифтов показывает, что в случае 1-комнатной квартиры также наблюдается прямая зависимость, а график имеет вид параболы. Стоимость резко увеличивается при наличии 4-х лифтов. Для 2-х комнатной рост стоимости более плавный, а для 3-комнатной квартиры стоимость повышается только после наличия в доме от 3-х лифтов.

График зависимости стоимости квартиры от площади показывает ее линейный характер для 1-комнатной и 2-х комнатной квартир. Для 1-комнатных квартир зависимость имеет более явный характер. При меньшем увеличении площади по сравнению с 2-комнатной квартирой стоимость растет больше. Для 3-х комнатной квартиры характер также является линейным, однако еще менее выраженным, по сравнению с 1-комнатными и 2-комнатными квартирами.




Рисунок 5. График зависимости стоимости квартиры от количества лифтов




Рисунок 6. График зависимости стоимости квартиры от площади




Рис. 7. Сравнение заявленных стоимостей и оцененных с помощью нейросети квартир

Данная сеть не является достаточно точной, так как не учитывает «центральность» объекта недвижимости, комфорт окружающего района. При этом сеть учитывает фактор «расстояние до метро», однако, в результате анализа видно, что этот фактор оказывает незначительное влияние на стоимость квартиры. Так, например, квартира в Центральном административном округе Москвы, будет стоить дороже, чем в периферийных районах. Для увеличения точности сети в дальнейшем, рекомендуется учесть данный фактор.

Благодарность. Работа выполнена при поддержке гранта РФФИ 19-010-00307 «Разработка интеллектуальной самоадаптируемой системы

массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости регионов РФ».

Библиографический список

1. Нейросимулятор 5.0 : свидетельство о гос. регистрации программы для ЭВМ № 2014618208, Российская Федерация / Ф.М. Черепанов, Л.Н. Ясницкий. — № 2014614649 ; зарегистр. 12.08.2014. — 1 с.
2. Ясницкий Л.Н. Введение в искусственный интеллект / Л.Н. Ясницкий. — М. : Академия, 2005. — 176 с.
3. Ясницкий В.Л. Нейросетевое моделирование в задаче массовой оценки жилой недвижимости города Перми // Фундаментальные исследования. 2015. — 176 с.
4. Ясницкий Л.Н., Ясницкий В.Л. Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости жилых объектов на примере рынков недвижимости Екатеринбурга и Перми // Имущественные отношения в РФ. 2017. №3 (186). с.13-17.

NEURAL NETWORK SYSTEM FOR EVALUATING THE COST OF MOSCOW APARTMENTS

Melenteva Aleksandra E.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

The article presents the results of the design and development of a system for assessing the cost of apartments in Moscow. When predicting the cost, the system takes into account factors, including the characteristics of the apartment and the house in which the apartment is located. It was studied how the cost of an apartment will change depending on its area, the floor on which it is located, the presence and number of elevators in the building.

Keywords: artificial intelligence, neural network technologies, market of apartments, valuation, forecasting, residential real estate.

АНАЛИЗ РЕЗЮМЕ КАНДИДАТОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕЙ И ЭКСПЕРТНЫХ СИСТЕМ ДЛЯ ОЦЕНКИ ПРОФЕССИОНАЛЬНОЙ ПРИГОДНОСТИ И ВОЗМОЖНОЙ БУДУЩЕЙ ЗАРПЛАТЫ

Портнов Михаил Дмитриевич, Бушуева Валерия Владиславовна
Национальный исследовательский ядерный университет “МИФИ”,
115409, Москва, Каширское ш., 31, mikport@gmail.com

Данная статья посвящена рассмотрению применения искусственного интеллекта в сфере управления человеческими ресурсами. Были проанализированы преимущества и недостатки использования нейросетевых технологий и рассмотрены решения проблем области с использованием искусственного интеллекта. В частности, была поставлена задача произвести анализ резюме кандидатов и на основе результатов данного анализа спрогнозировать возможную заработную плату. Выделены требуемые параметры для оценки резюме кандидатов перед собеседованием с помощью нейросетей.

Ключевые слова: машинное обучение, методы оценки, бизнес-аналитика, интеллектуальные информационные системы, нейросетевые технологии.

Зарботная плата является одним из инструментов для достижения стратегических целей различных компаний и учреждений. При приеме человека на работу перед руководителем возникает сложная задача определить размер предлагаемой заработной платы, основываясь пока лишь на сведениях из резюме соискателя: уровень образования, опыт работы, профессиональные навыки и т.д. Также руководитель должен учитывать ставки для данной вакансии, действующие на внешнем рынке труда, и свои финансовые возможности.

Преимущества, которые стоит отметить при использовании искусственного интеллекта (ИИ) в HR-профессии, можно увидеть ниже.

Снижение человеческой предвзятости

При всех стараниях казаться объективными, рекрутеры так или иначе остаются в какой-то степени предвзяты, отдавая предпочтение определенным кандидатам не в пользу их навыков, а, например, каких-то интересов. У ИИ нет предубеждений и стереотипов, и поэтому экспертные системы по отбору персонала с использованием ИИ принимают решения о найме претендента, основываясь лишь на его навыках и достижениях.

Автоматизация, масштабируемость

Конкуренция среди квалифицированных специалистов растет, и выбор становится делать все сложнее и дольше. ИИ может позволить избавиться руководству от решения рутинных задач, концентрируя внимание на общих

тенденциях компании, отбирая большое количество людей по определенным критериям.

ИИ может сам находить работников из открытых источников по определенным запросам работодателя, оценивая возможный будущий срок пребывания кандидата в должности, а также возможных ожидаемых результатов.

Оценка эффективности производимой сотрудниками компании работы

ИИ-платформы могут отслеживать деятельность сотрудников на их корпоративных устройствах, собирая нужную статистику (активное время, проведенное в конкретных программах, соотнесение результатов работы с поставленными целями, проверка дедлайнов).

Проблемы, которые ИИ может внести в деятельность компаний, готовых использовать технологии, связаны с адаптацией сферы деятельности с ИИ, а также с отсутствием доверия к ИИ. Очень важно правильно понимать, как надо применять искусственный интеллект при работе с кадрами предприятия.

Одним из вариантов решения поставленной задачи может оказаться создание экспертной системы на основе интеллектуального анализа данных. Это достаточно эффективный метод, который можно использовать для сбора и обработки данных резюме. Нейросеть на основе данных, представленных в резюме, сможет спрогнозировать рабочее поведение будущего сотрудника: его производительность, возможность увольнения, особые навыки в команде. Все это должно производиться с целью улучшения отбора персонала и набора кандидатов для выполнения конкретных должностных функций.

Для анализа текста резюме с точки зрения его тональности на случай анализа мотивации претендента можно использовать сверточные нейросети — инструменты дистрибутивной семантики, такие как Word2Vec, Glove, FastText и т.д. для определения эмоциональной составляющей, и, как следствие, приоритизации на основе этих данных людей в списках отбора.

Отбор подходящих кандидатов из большого списка претендентов является сложной задачей: работникам по найму персоналу приходится просматривать и оценивать множество профилей соискателей, отвечать на их вопросы, проводить собеседования. Для выполнения таких рутинных задач, как просмотр резюме и общение с кандидатом, можно использовать чат-ботов, умеющих обрабатывать естественный язык. После принятия заявки от претендента на вакансию, чат-бот начинает интервьюировать его (по вопросам, составленным рекрутерами) и оценивает ответы, а также отвечает на вопросы соискателя и выставляет ему оценку. В качестве материала для обучения чат-бота можно использовать ответы претендентов и отзывы о них от рекрутеров. Полученные ответы и выставленные оценки уже чат-ботом стоит сохранять для дальнейшего обучения с целью улучшения взаимодействия с будущими соискателями. Преимуществом использования таких чат-ботов является непрерывность коммуникации; при переписке

между соискателем и работодателем могут возникать паузы ввиду загруженности обеих сторон, и в итоге общение может прерваться.

Основная задача любых экспертных систем передать опыт из конкретной области человека компьютеру. Здесь они могут использоваться руководителями для помощи в принятии решений по отбору персонала. Например, можно дополнительно оценивать кандидатов по результатам тестов, рейтингу производительности, способностям. В зависимости от выбираемых должностей критерии могут заменять друг друга или дополняться: начиная физическими параметрами и заканчивая узконаправленными навыками из конкретной области. Несмотря на тему текущего исследования, важно отметить, что такой подход может быть использован не только в приеме кадров на работу, но и при поступлении абитуриентов в высшие учебные заведения на различные профили. Это сможет повысить уровень образования — легче будет определять более заинтересованный в получении профильного образования круг лиц.

Для оценки предполагаемой зарплаты сотрудника можно обучить нейросеть на основе данных о вакансиях и соответствующих им зарплатам, воспользовавшись API hh.ru для сбора данных. Для обучения нейронной сети предъявляются входные (данные о вакансиях) и выходные (соответствующие вакансиям зарплаты) сигналы, и по определенному алгоритму она подстраивает веса своих синаптических связей. В требуемый набор данных можно вынести следующие показатели: выполнение квалификационных требований, готовность выполнения сотрудником трудовых обязанностей на новом конкретном рабочем месте, практические знания информационных технологий на своем рабочем месте, потребность в образовании и самообразовании, уровень профессионального соответствия выставленным критериям и т.д.

Для реализации задачи нужно обучить нейросеть на данных с открытых источников (hh.ru api, kaggle) и добавить пользовательский, например, веб-интерфейс для удобного взаимодействия с запросами к системе.

Таким образом, создав такую модель, мы сможем приблизительно оценивать зарплату требуемых сотрудников, опираясь на текущие данные рынка труда. Данная систем упростит принятие соглашения об оплате труда будущего сотрудника и улучшит процесс привлечения новых кандидатов.

Библиографический список

1. AI in Human Resources [Электронный ресурс]
URL: <https://www.oracle.com/a/ocom/docs/applications/hcm/oracle-ai-in-hr-wp.pdf> (дата обращения: 25.09.2020).
2. AI in HR [Электронный ресурс]
URL: <https://www.hrexchangenetwork.com/hr-tech/articles/ai-in-hr> (дата обращения: 25.09.2020).
3. Jobs on Naukri.com [Электронный ресурс]
URL: <https://www.kaggle.com/promptcloud/jobs-on-naukricom> (дата обращения: 25.09.2020).

4. The application of Artificial Intelligence (AI) in Human Resource Management [Электронный ресурс]
URL: <https://www.divaportal.org/smash/get/diva2:1322478/FULLTEXT01.pdf> (дата обращения: 25.09.2020).
5. Will Artificial Intelligence Take Over Humanresources Recruitment And Selection? [Электронный ресурс]
URL:https://www.researchgate.net/publication/337931190_WILL_ARTIFICIAL_INTELLIGENCE_TAKE_OVER_HUMANRESOURCES_RECRUITMENT_AND_SELECTION (дата обращения: 25.09.2020).
6. Армстронг М., Тэйлор С. Практика управления человеческими ресурсами // Kogan Page Publishers, 2006, С.533-633.

ANALYSIS OF APPLICANTS' CV WITH USE OF NEURAL NETWORKS AND EXPERT DECISION SYSTEMS FOR ASSESSING OF PROFESSIONAL SUITABILITY AND POSSIBLE FUTURE SALARY

Portnov Mikhail D., Bushueva Valeria V.

National Research Nuclear University «Moscow Institute of engineering and physics»

115409, Russia, Moscow, Kashirskoye Highway, 31, mikport@gmail.com

This article considers the application of artificial intelligence in the area of human resources management. By analyzing advantages and disadvantages of using neural network technologies, there were suggested solutions to the problems in the field of artificial intelligence. In particular, it was tasked to analyze CV of candidates and to predict their possible salary on the basis of received outcomes.

Keywords: machine learning, methods of assessing, business analytics, intellectual information systems, neural network technologies.

Научное издание

**Интеллектуальные системы в науке и технике.
Искусственный интеллект в решении актуальных социальных
и экономических проблем XXI века**

Сборник статей по материалам
Международной конференция «Интеллектуальные системы
в науке и технике» и Шестой всероссийская научно-практической
конференции «Искусственный интеллект в решении актуальных
социальных и экономических проблем XXI века»
(г. Пермь, 12–18 октября 2020 г.)

Ответственный редактор
Л. Н. Ясницкий

Издается в авторской редакции
Компьютерная верстка: *Т. С. Карина*

Объем данных 16,7 Мб
Подписано к использованию 03.11.2020

Размещено в открытом доступе
на сайте www.psu.ru
в разделе НАУКА / Электронные публикации
и в электронной мультимедийной библиотеке ELiS

Издательский центр
Пермского государственного
национального исследовательского университета
614990, г. Пермь, ул. Букирева, 15

ОРГАНИЗАТОРЫ:



Министерство
образования
и науки
Пермского края

СПОНСОРЫ
И ПАРТНЕРЫ
МЕХАНИКО-
МАТЕМАТИЧЕСКОГО
ФАКУЛЬТЕТА:



Ростелеком
Информационные Технологии

BioNT
ВАША ИНФОРМАЦИЯ
ПОД НАДЕЖНОЙ ЗАЩИТОЙ

BOTAN
INVESTMENTS

PARMA
Technologies Group