

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

**Часть 2**

**Пермь 2024**

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ  
РОССИЙСКОЙ ФЕДЕРАЦИИ  
Федеральное государственное автономное  
образовательное учреждение высшего образования  
«ПЕРМСКИЙ ГОСУДАРСТВЕННЫЙ  
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ»

*Посвящается памяти Юрия Владимировича Девингталя,  
основателя первого в г. Перми вычислительного центра  
и кафедры прикладной математики ПГНИУ*

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

Сборник статей по материалам Девятой всероссийской  
научно-практической конференции с международным участием  
(г. Пермь, ПГНИУ, 17–18 октября 2024 г.)

### **Часть 2**

«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.*



Пермь 2024

УДК 004.8: 3  
ББК32.813 + 6/8  
И868

**Искусственный** интеллект в решении актуальных социальных  
И868 и экономических проблем XXI века : сборник статей по материалам  
Девятой всероссийской научно-практической конференции с между-  
народным участием (г. Пермь, ПГНИУ, 17–18 октября 2024 г.) / под  
редакцией Л. Н. Ясницкого, Т. В. Миролубовой, М. В. Радионовой,  
Е. Г. Плотниковой ; Пермский государственный национальный ис-  
следовательский университет. – Пермь, 2024. – Ч. 2. – 256 с.

ISBN 978-5-7944-4170-3  
ISBN 978-5-7944-4172-7 (Ч. 2)

В сборнике представлены материалы Девятой всероссийской научно-  
практической конференции с международным участием «Искусственный ин-  
теллект в решении актуальных социальных и экономических проблем XXI ве-  
ка», которая проводилась 17–18 октября 2024 г. в г. Перми.

Сборник предназначен для научных и педагогических работников, препо-  
давателей, аспирантов, магистрантов, студентов и всех, кто интересуется про-  
блемами и перспективами развития и применения методов искусственного ин-  
теллекта.

УДК 004.8: 3  
ББК 32.813 + 6/8

*Издается по решению ученого совета экономического факультета  
Пермского государственного национального исследовательского университета*

#### **Партнёры конференции:**

Пермское отделение Научного совета при президиуме РАН  
по методологии искусственного интеллекта

Российская ассоциация искусственного интеллекта

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

*Рецензенты:* президент Российской ассоциации искусственного интеллекта,  
профессор кафедры вычислительной техники Смоленского фи-  
лиала НИУ «МЭИ», д-р техн. наук, профессор **В. В. Борисов**;  
д-р техн. наук, профессор **О. Г. Пенский**

ISBN 978-5-7944-4170-3  
ISBN 978-5-7944-4172-7 (Ч. 2)

© ПГНИУ, 2024

## ОГЛАВЛЕНИЕ

<b>Искусственный интеллект и экология, демография, окружающая среда.....</b>	<b>7</b>
<i>Катаев С.А., Русаков С.В.</i>	
Нейросетевые модели для прогнозирования весеннего половодья на реке Кама в районе гидропоста Бондюг.....	7
<i>Дорошенко Т.А., Самсонова Н.А.</i>	
Применение алгоритмов машинного обучения для анализа факторов рождаемости в рамках нового национального проекта «Семья».....	13
<i>Калабихина И.Е., Казбекова З.Г., Мошкин В.С., Колотуша А.В., Таипов М.М., Фаттахов Т. А., Полетаев Д.В., Зайцев И.С.</i>	
Демографические аспекты отказа от курения (на основе данных социальных медиа и применения нейросетей).....	20
<i>Явеев Р.Р., Поляков М.В.</i>	
Метод машинного обучения на основе сгенерированных астрофизических данных для определения количества спиралей галактик.....	24
<i>Резанов К.В., Поляков М.В.</i>	
Интеллектуальный анализ астрометрических данных космического телескопа GAIA.....	28
<i>Кликунова А.Ю., Хоперсков А.В.</i>	
Влияние размера обучающей выборки нейросети на точность определения параметров гидравлического сопротивления в модели мелкой воды.....	34
<i>Панафидин М.Н., Бутенко М.А.</i>	
Классификация галактик по морфологическим типам с использованием искусственных нейронных сетей.....	38
<b>Искусственный интеллект, педагогика и образование.....</b>	<b>44</b>
<i>Домбрин И.М.</i>	
О причинах последствий применения технологий искусственного интеллекта в школе.....	44
<i>Кузнецов А.Г., Черепанов Ф.М., Ясницкий Л.Н.</i>	
Современные проблемы высшего образования РФ и искусственный интеллект.....	50
<i>Горелик С.Л., Грудинин В.А.</i>	
Формирование динамического рейтинга учащихся в образовательном процессе.....	56
<i>Рыжкова М.В., Былкова Т.В., Непомнящая Ю.А., Беляк Д.К.</i>	
Использование генеративного искусственного интеллекта в решении образовательных и прикладных задач: экспериментальный подход.....	61
<i>Федяев О.И., Суханов А.А.</i>	
Нейросетевое распознавание лиц в видеопотоке системы автоматического контроля присутствия студентов на занятии.....	64



<i>Попов Б.С.</i>	
Развитие ИИ-грамотности и критического мышления.....	71
<i>Орлова Т.С.</i>	
Генеративные и адаптивные модели искусственного интеллекта в решении образовательных задач.....	77
<i>Самылкина Н.Н.</i>	
Вариативное обучение основам искусственного интеллекта в школьном курсе информатики.....	81
<i>Лелюх А.Б.</i>	
Развитие ИИ-технологий в образовании: обзор современных инструментов и их применение.....	88
<i>Кобзев И.Д., Мочалова В.К., Лесниченко-Роговская М.В.</i>	
Исследование актуальности использования ИИ в образовательном процессе в школе.....	94
<i>Садыкова Г.В., Каюмова А.Р.</i>	
Концепция модели интеграции технологий искусственного интеллекта в билингвальные программы для детей дошкольного возраста.....	98
<i>Худякова А.В.</i>	
Проектирование и реализация внеурочных мероприятий по искусственному интеллекту для обучающихся 10–11 классов.....	103
<b>Искусственный интеллект, лингвистика и обработка текста.....</b>	<b>107</b>
<i>Кузьмин А.Н.</i>	
Внедрение технологий больших языковых моделей в мессенджеры.....	107
<i>Калабин А.Л.</i>	
Оценка связности текста методами кластеризации.....	111
<i>Лаптев А.К.</i>	
Интеллектуальный анализ дневника Ф.П. Литке: большие языковые модели и метаданные в процессе обработки естественного языка.....	117
<i>Кукса В.К., Поляков М.В.</i>	
Разработка и особенности применения нейросетевой системы для проверки оригинальности текста.....	124
<i>Москвитина А.М., Москвитин В.А.</i>	
AI и лингвистическая идентичность: как искусственный интеллект влияет на языковую культуру и разнообразие.....	128
<i>Неверов А.Р.</i>	
Автоматизация повышения качества работы нейросетевой модели.....	132
<i>Ивутин А.Н., Савенков П.А., Волошко А.Г., Крюков О.С.</i>	
Исследование методов извлечения индивидуальных признаков эмоциональной окраски из коллекции пользовательских текстов.....	137
<i>Шпирко С.В.</i>	
Об одном подходе к интеллектуальному анализу текстов.....	143

<b>Искусственный интеллект, социология, политология, психология и криминалистика.....</b>	<b>148</b>
<i>Ильина Е.Н.</i>	
Трудовое поведение в эпоху искусственного интеллекта.....	148
<i>Липин Ю.Н.</i>	
Алгоритм и программное обеспечение распознавания монозиготных близнецов и отцовства.....	154
<i>Осмоловская А.А.</i>	
Тенденции изменения информированности избирателей в связи с использованием искусственного интеллекта.....	160
<i>Пономарев А.Ф.</i>	
Нейросетевая система прогнозирования склонности к серийным убийствам.....	164
<i>Трусова В.А., Поляков М.В.</i>	
Интеллектуальный анализ данных для исследования характеристик психологического состояния.....	168
<b>Искусственный интеллект и спорт.....</b>	<b>174</b>
<i>Корепанов С.А.</i>	
Нейросетевая система прогнозирования победителя матча футбольной команды Ливерпуль в рамках Английской Премьер-лиги.....	174
<i>Пачин А.Д.</i>	
Нейросетевая система прогнозирования результатов команд российской премьер-лиги в конце сезона.....	180
<i>Решетников М.А.</i>	
Создание нейросетевой модели для прогнозирования исхода поединка в смешанных единоборствах.....	187
<i>Росихина Е.М.</i>	
Нейросетевая система прогнозирования результатов кубка мира по биатлону.....	193
<b>Развитие технологий искусственного интеллекта.....</b>	<b>198</b>
<i>Гладкий С.Л.</i>	
Проблемы нейросетевых моделей в задачах компьютерного зрения и пути развития объяснимого искусственного интеллекта.....	198
<i>Бочкарев В.А.</i>	
Поиск выбросов в статических данных относительно зависимого признака.....	202
<i>Лосев А.Г.</i>	
О некоторых проблемах формирования обучающих наборов данных в искусственном интеллекте.....	207

<i>Попов И.Е.</i> Использование нейронных сетей в системе объяснимого искусственного интеллекта.....	211
<i>Гладкий С.Л.</i> Устранение цветовой зависимости сверточных нейронных сетей в задачах компьютерного зрения.....	214
<i>Холопов В.А., Благовещенский И.Г., Макаров М.А.</i> Метод компоновки роботизированных технологических комплексов на основе объединения систем координат с применением машинного зрения.....	223
<i>Окусков И.С.</i> Применение искусственного интеллекта на этапах жизненного цикла программного обеспечения.....	227
<i>Сапегин А.А.</i> Улучшение видимости объектов на изображении при помощи нейросети.....	232
<i>Соколов А.В., Сычев И.А., Хейфец И.И., Соколова О.Л.</i> Теоретические и практические аспекты построения рекомендательных моделей: типология, архитектура и направления проектирования.....	236
<i>Щёголева Н.В., Сергеев С.Ф.</i> Особенности эргономики систем с генеративным искусственным интеллектом.....	241
<i>Зотина Г.В., Эстер М.В., Кедров А.В.</i> Опыт применения библиотеки машинного зрения для анализа породного состава лесных насаждений на основе данных аэрофотосъемки....	246
<i>Сергеев А.В., Плешаков А.О., Сергеев С.Ф.</i> Виртуальные инструменты в интерфейсах управления промышленными роботами.....	252

## **Секция: Искусственный интеллект и экология, демография, окружающая среда**

УДК 004.032.26

### **НЕЙРОСЕТЕВЫЕ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ВЕСЕННЕГО ПОЛОВОДЬЯ НА РЕКЕ КАМА В РАЙОНЕ ГИДРОПОСТА БОНДЮГ**

***Катаев Сергей Александрович***

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
sergk1780@mail.ru

***Русаков Сергей Владимирович***

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
rusakov@psu.ru

В статье представлено описание двух нейросетевых моделей для прогнозирования весеннего половодья на р.Кама. В качестве исходных данных используются результаты многолетних наблюдений в районе гидропоста п. Бондюг. Полученные модели позволяют с удовлетворительной точностью прогнозировать уровень воды в реке на 5 дней вперед.

**Ключевые слова:** прогнозирование весеннего половодья, предобработка больших объемов данных, нейросетевая модель.

**Введение.** Весеннее половодье, наступающее в результате активного снеготаяния, происходит на большинстве рек России. В этот относительно небольшой промежуток времени формируются наибольшие в году расходы воды, приводящие к выходу воды из меженного русла и затоплению поймы. Последствиями данного явления становится затопление обширных территорий, повреждение или разрушение зданий, дорог, сооружений, уничтожение растительного и животного мира в районе разлива рек. В зонах, подверженных потенциальному влиянию половодий, расположено множество населенных пунктов, промышленных объектов, объектов инфраструктуры, сельскохозяйственных территорий. По оценкам Росгидромета наводнения на реках занимают первое место по суммарному среднегодовому ущербу среди всех опасных природных явлений (прямые экономические потери от наводнений составляют более 50% общего ущерба) [1].

Постоянство весеннего половодья в бассейне данной реки позволяет относительно надежно прогнозировать его появление, но не его параметры: дату начала, продолжительность, расход и уровень воды в реке. Знание поведения реки на некоторый срок вперед позволит оповестить о возможном возникновении опасных явлений компетентные службы и уменьшить, или даже полностью предотвратить возможные катастрофические последствия паводка.

Выделяют четыре группы факторов, участвующих в формировании весеннего половодья: климатические, антропогенные, геоморфологические, растительные [2]. Климатические факторы оказывают наибольшее влияние на масштабы половодья, самые существенные из них – осадки и температура. Они определяют продолжительность прохождения половодья его максимальный расход и общий объем. Чуть менее влияющими являются геоморфологические факторы. Также роль в формировании половодья имеют антропогенные факторы и факторы растительности. Они влияют в основном на накопление осадков на водосборе и распределение их по поверхности. Таким образом, для работы системы прогноза необходима оперативная и прогностическая метеорологическая информация об осадках, температуре воздуха и точки росы, скорости ветра, облачности, данные о ежедневных расходах воды в створах гидрологических постов, требуются статические данные: электронные топографические карты высокого разрешения, карты землепользования, типов почв, речной сети. В итоге получается сложная нелинейная система с множеством факторов влияния, причем, данные о некоторых из входных параметров не могут быть получены своевременно или в полном объеме.

Одним из наиболее эффективных подходов к прогнозированию параметров сложных нелинейных систем являются нейронные сети, так как они позволяют учесть нелинейный характер и взаимовлияние между разнородными параметрами их состояния [3]. Использование нейросетевых моделей относится к статистическим методам. Обычно их используют для прогнозирования половодья в районе конкретного гидрологического поста. Причина этого заключается в наличии базы данных измерений этого гидропоста, которые в свою очередь необходимы для процесса обучения нейросети [4].

**Методика исследования и полученные результаты.** Цель настоящей работы заключается в проектировании и обучении нейросетевой модели на основе обработки многолетних данных об уровне и расходе воды на реке Кама в районе гидропоста Бондюг. Конечным результатом должна быть нейросетевая система, способная прогнозировать уровень воды в районе расчетного гидропоста на несколько дней вперед с ошибкой не более 5-6%. Для реализации этой задачи применялся алгоритм интеллектуального анализа данных методом нейросетевого математического моделирования [5].

Обучающее множество, оцифрованное из гидрологических сборников, представляет собой непрерывный временной ряд ежедневных данных об уровне и расходе воды с 1955 по 1985 и с 2008 по 2015 гг. замеренных и рассчитанных на гидропосте Бондюг реки Кама.

Как видно на рис. 1, после стабильных зимних значений уровня и расхода воды следует резкий подъем этих параметров весной. Перед проектированием и обучением нейросетевой модели, была выполнена обработка данных с помощью Microsoft Excel и макроса на VBA.

С помощью макроса для каждого года были определены характерные параметры: день начала весеннего допаводкового периода (ДНДП) – день, когда расход воды увеличивался в 1.7 раза по сравнению с средне-зимним расходом

воды, максимальный уровень воды при паводке, максимальный расход воды при паводке и др.




Рис. 1. Уровень и расход воды на гидропосте Бондюг р. Кама 1965 г.




Рис. 2. Формирование обучающего множества из данных о расходе воды методом «окон»

Одним из гиперпараметров является день в году, выбранный для начала обучения, т. е. первый день в каждом году, начиная с которого формируются обучающие примеры. Для корректной работы прогноза в период слабо меняющихся входных параметров необходимо, чтобы нейросеть обучалась в некотором промежутке времени до ДНДП, поэтому выбирается день начала обучения: на 10 дней раньше ДНДП.

Для получения обучающего и валидационного множества из значений уровня воды был выбран метод формирования так называемого «окна», размер которого будет являться одним из гиперпараметров нейронной сети. В ходе исследования было получено, что лучшие результаты дает окно размером в 10 дней, значения уровня воды в первые 5 дней из этого окна являются входными параметрами, а значения в 5 последних дней – выходными параметрами (целями). Аналогично создавалось множество из значений расхода воды, при этом размер окна и начальная дата формирования этих двух множеств должны быть одинаковыми. Таким образом, получилась одна строка обучения, содержащая 10 входных (5 – уровень воды, 5 – расход воды) и 10 выходных параметров (5 – уровень воды, 5 – расход воды). Далее данное окно, не изменяя размера, сдвигалось на один день вперед и получалась вторая строка обучающего множества (рис. 2).

За последний день, переданный на входной нейрон X1, принимается день максимального уровня воды при паводке, таким образом, в обучающий пример попадают еще несколько следующих за ним дней (количество дней зависит от размера окна, на рис. 2 таких дней будет 4).

Полученные таким образом строки обучающего множества перемешивались между собой в случайном порядке во всем объеме данных за исследуемые годы (кроме 1979 г.). Далее множество разбивалось случайным образом на обучающее и валидационное. Размер валидационного множества составляет 10% от обучающей выборки. В качестве тестового множества выбран 1979 год

наблюдения полностью, данные за этот год не участвуют в обучении, проверке и валидации нейросетевой модели.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор Nsim5-10s» [6].

Спроектированная нейронная сеть имела следующую структуру: десять входных нейронов: X1 – X5 – уровень воды за 5 дней подряд (на рис. 2 в желтой рамке), X6 – X10 – расход воды за 5 дней подряд, десять выходных нейронов: Y1 – Y5 – прогноз уровня воды на 5 дней вперед (на рис. 2 в красной рамке), Y6 – Y10 – прогноз расхода воды на 5 дней вперед. Далее производилось выбор параметров нейросети вручную, путем пошагового изменения количества скрытых слоев, количества нейронов на каждом скрытом слое, функции активации, скорости обучения и количество итераций обучения.

Оценка оптимальности сети выполнялась по величине средней относительной ошибки на валидационном множестве. В результате оптимизации нейронная сеть (НС1) имела следующую структуру: десять входных нейронов, десять выходных нейронов, три скрытых слоя с 9, 8, 8 нейронами соответственно, функция активации всех нейронов – гиперболический тангенс, количество итераций обучения – 7000.

Ошибка прогноза с каждым следующим прогнозируемым днем возрастает на 2-3 %, несмотря на это, самые важные параметры: максимальный уровень воды и день максимального уровня воды прогнозируются с достаточной точностью. Погрешности результатов прогноза, полученные на обучающей выборке, представлены в табл.

Таблица

Средние относительные ошибки (%) в разрезе расхода воды, уровня воды и количества прогнозируемых дней									
Y1	Y2	Y3	Y4	Y5	Y6	Y7	Y8	Y9	Y10
1.6	2.3	3.6	5.1	6.3	1.5	2.5	3.3	4.7	6.3

Оценка значимости входных параметров, выполненная с помощью программы «Нейросимулятор 5», показала её возрастание при приближении к дню, предшествующему прогнозируемому периоду.

Поскольку первоочередной задачей исследования является прогноз максимального уровня воды в реке, была построена и оптимизирована сеть (НС2) со следующей структурой: десять входных нейронов, пять выходных нейронов (Y1 – Y5 – прогноз уровня воды на 5 дней вперед), два скрытых слоя с 8 и 6 нейронами соответственно, функция активации всех нейронов – гиперболический тангенс, количество итераций обучения – 7000.

Данная нейросетевая модель показала стабильное улучшение параметров качества прогноза для всех пяти дней прогноза на 0,3-0,5%. Для финальной оценки работы нейронной сети использовалось тестовое множество за 1979 год.




Рис. 3. Прогноз уровня воды в 1979 году на 1 день вперед




Рис. 4. Прогноз уровня воды в 1979 году на 2 дня вперед




Рис. 5. Прогноз уровня воды в 1979 году на 3 дня вперед




Рис. 6. Прогноз уровня воды в 1979 году на 4 дня вперед

На рис. 3-6 представлены графики, демонстрирующие расхождение между фактическим и прогнозируемым нейросетью уровнем воды в 1979 году для 1, 2, 3 и 4 дня вперед.

**Заключение.** Построена система нейросетевого прогнозирования уровня и расхода воды (НС1) и система нейросетевого прогнозирования уровня воды (НС2) на реке Кама в районе гидропоста Бондюг. Спроектированные с помощью программы «Нейросимулятор 5» и алгоритма интеллектуального анализа данных методом нейросетевого математического моделирования нейросетевые модели принимают на вход всего лишь два вида параметров: уровень воды за 5 дней и расход воды за 5 дней, и выдают на выходе с удовлетворительной точностью прогноз на 5 дней вперед для уровня и расход воды (НС1) и только для уровня воды (НС2).



## Библиографический список

1. Стратегический прогноз изменений климата Российской Федерации на период с 2010 по 2015 гг. и их влияние на отрасли экономики России // Федеральная служба по гидрометеорологии и мониторингу окружающей среды (Росгидромет). – М.: 2005. С. 9.
2. Владимиров, А. М. Факторы, определяющие возникновение экстремальных расходов и уровней воды половодья // Ученые записки Российского государственного гидрометеорологического университета. – 2009. – № 9. С. 22-24.
3. Хайкин С. Нейронные сети: полный курс. М.: Издательский дом «Вильямс», 2006. С. 1104.
4. Волчек А. А., Костюк Д. А., Петров Д. О., Шешко Н. Н. Метод прогнозирования половодий на основе многофакторного нейросетевого анализа // Вестник Брестского государственного технического университета. Физика, математика, информатика. – 2018. – № 5(113). – С. 53-55.
5. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 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 MODELS FOR FORECASTING SPRING FLOODS ON THE KAMA RIVER IN THE AREA OF THE BONDYUG HYDROPOST

*Kataev Sergey Alexandrovich*

Perm State National Research University,  
15 Bukireva str., Perm, 614068, Russia  
sergk1780@mail.ru

*Rusakov Sergey Vladimirovich*

Perm State National Research University,  
15 Bukireva str., Perm, 614068, Russia  
rusakov@psu.ru

The article describes two neural network models for predicting spring flooding on the Kama River. The results of long-term observations in the area of the Bondyug hydropost are used as initial data. The obtained models allow predicting the water level in the river with satisfactory accuracy for 5 days ahead.

**Keywords:** forecasting of spring floods, preprocessing of large amounts of data, neural network model.

## **ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ФАКТОРОВ РОЖДАЕМОСТИ В РАМКАХ НОВОГО НАЦИОНАЛЬНОГО ПРОЕКТА «СЕМЬЯ»**

***Дорошенко Татьяна Андреевна***

Федеральное автономное научное учреждение  
«Восточный центр государственного планирования»,  
127025, Россия, г. Москва, ул. Новый Арбат, д. 19  
t.doroshenko@vostokgosplan.ru

***Самсонова Наталья Александровна***

Федеральное автономное научное учреждение  
«Восточный центр государственного планирования»,  
127025, Россия, г. Москва, ул. Новый Арбат, д. 19  
n.samsonova@vostokgosplan.ru

Статья рассматривает модель, включающую алгоритмы машинного обучения, применяемую для определения факторов изменения показателя суммарного коэффициента рождаемости в контексте нового национального проекта "Семья" и мероприятий демографической политики. Исследование базируется на данных по социально-экономическому развитию и включает оценку и ранжирование факторов, влияющих на демографические показатели. Представлены методы корреляционного анализа и модели машинного обучения, включая RandomForestRegressor, для прогнозирования вклада предлагаемых мероприятий на достижение национальных целей в области демографии.

**Ключевые слова:** машинное обучение, RandomForestRegressor, случайный лес для регрессии, факторы рождаемости, суммарный коэффициент рождаемости.

**Введение.** В 2024 году заканчивают свой цикл действующие национальные проекты и Правительство России уже начало активную работу над разработкой новых национальных проектов и входящих в них федеральных. В частности, ведется разработка содержания национального проекта «Семья» [1], который приходит на смену нацпроекта «Демография». Новый нацпроект призван обеспечить достижение таких национальных целей как сохранение населения, укрепление здоровья и повышение благополучия людей, поддержка семей, а также реализация потенциала каждого человека, развитие его талантов [2-3]. Согласно новому майскому указу Президента России к целевым показателям по данным целям относятся: повышение суммарного коэффициента рождаемости, увеличение ожидаемой продолжительности жизни, снижение уровня бедности, продвижение и защита традиционных российских духовно-нравственных ценностей [3] и др.

Утверждено, что в нацпроект «Семья» будут включены пять федеральных проектов [3], в рамках которых будут спланированы мероприятия по достижению поставленных целей. Перед государственными деятелями стояла задача сделать предварительную оценку вклада предлагаемых мероприятий в дости-

жение национальных целей. Перед научным сообществом также встанет задача сделать прогнозные оценки после того, как перечень мероприятий будет опубликован.

Для оценки вклада мероприятий, а также ранжирования их по масштабу вклада можно применять инструменты искусственного интеллекта, например, различные алгоритмы машинного обучения.

В общем случае методика оценки вклада реализации демографических мер, направленных на повышения рождаемости – на рост показателя суммарный коэффициент рождаемости (далее – СКР), приведена на рис. 1.

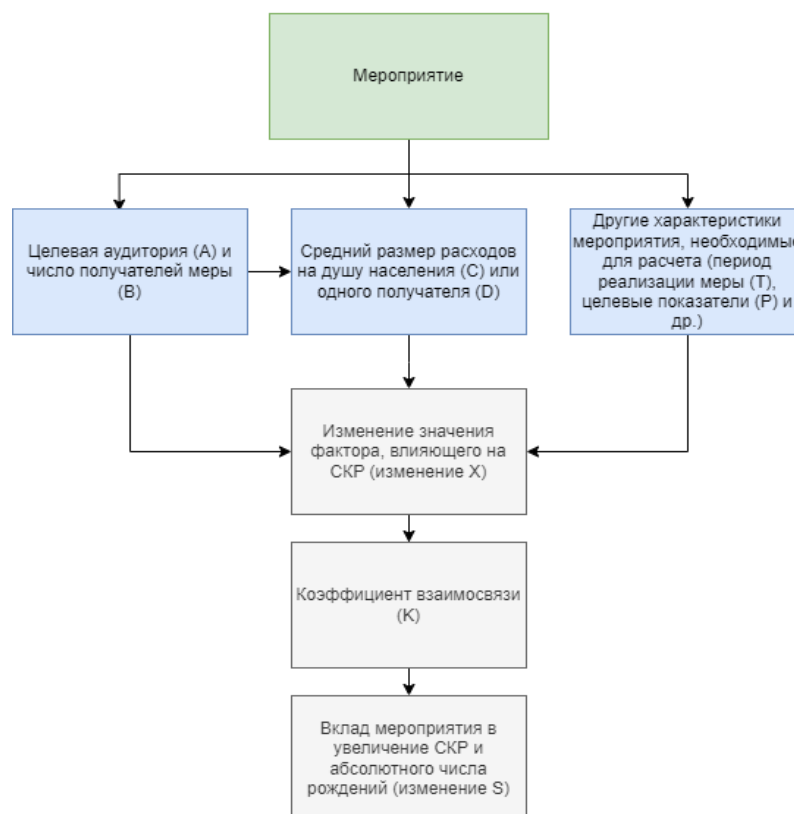


Рис. 1. Схема методики оценки вклада реализации демографических мер, направленных на повышение суммарного коэффициента рождаемости

Параметр  $S$  – это искомый верхнеуровневый показатель, в данном случае вклад в изменение СКР. Параметры  $A$ ,  $B$ ,  $C$ ,  $D$ ,  $T$  и  $P$  являются сценарными для оценки и определяются исходя из утвержденных показателей (например, период реализации меры и средний размер материальной помощи) или из данных ведомственной статистики и прогнозов на их основании (целевая аудитория и число потенциальных выгодоприобретателей). Параметр  $X$  – это фактор, который будет влиять на рождаемость (СКР) и на который одновременно влияют сценарные параметры мероприятия (изменение значения фактора  $X$  является производным от изменения сценарных параметров). Коэффициент взаимосвязи  $K$  (коэффициент регрессии) – это коэффициент, определяющий на сколько, изменится искомый показатель (СКР) при изменении фактора  $X$ .

**Постановка задачи и формирование набора данных.** В данной работе мы рассмотрим модель, включающую алгоритмы машинного обучения, применяемую для определения факторов изменения показателя СКР (число детей,

рожденных женщиной в репродуктивный период), потенциально изменяющихся под воздействием мероприятий демографической политики (параметр X).

Для этого, по публичным выступлениям Президента России, Правительства России и анализу действующей политики, сделаны экспертные предположения о том, на какие факторы и показатели социально-экономического развития могут повлиять мероприятия и как потом эти факторы повлияют на показатели рождаемости.

В первоначальную базу данных вошли 55 показателей по 85 субъектам Российской Федерации за период 2013-2022 годы (1 – зависимая переменная, 54 – гипотетических факторов). Эти показатели были проверены на нормальность с применением следующих методов:

1. графических:

а) гистограммы: для визуальной оценки распределения данных;

б) Q-Q (квантиль-квантиль) графики: для визуальной оценки отклонений данных от нормального распределения;

2. статистические тесты:

а) тест Шапиро-Уилка: используется для проверки гипотезы о нормальности распределения данных;

б) тест Андерсона-Дарлинга: тест для проверки нормальности;

в) тест Колмогорова-Смирнова: проверяет гипотезу, что данные следуют нормальному распределению.

В результате ряд показателей был исключен из выборки и ряд показателей был нормализован (прологарифмирован).

Для дальнейшего отбора факторов был проведен корреляционный анализ. В итоге, среди показателей, влияющих на параметр СКР (выходной, верхнеуровневый показатель), были выделены следующие, на которые могут оказывать прямое или косвенное влияние мероприятия нацпроекта «Семья» и другие меры социальной политики:

– средний возраст матери при рождении первого ребёнка (мероприятия по стимулированию раннего родительства и поддержке молодых семей);

– доля сельского населения в общей численности населения (мероприятия по развитию сельских территорий);

– число браков в расчете на 1000 населения за год (мероприятия по укреплению института брака);

– заболеваемость на 1000 человек населения (мероприятия, обеспечивающие сохранение и укрепление здоровья);

– среднее число участников клубных формирований, посещений мероприятий концертных организаций, самостоятельных коллективов, проведенных собственными силами в пределах своей территории и платных мероприятий парков в расчете на 1 тыс. человек населения (социализация личности посредством вовлеченности в креативную деятельность и досуговую среду);

– численность зрителей театров и число посещений музеев на 1000 человек (повышение качества и доступности услуг в сфере культуры);

– число автобусов общего пользования на 100 000 человек населения (рост обеспеченности общественным транспортом);

- средняя цена 1 кв. м общей площади первичных и вторичных квартир на рынке жилья за год (улучшение жилищных условий);
- пособия, компенсации и др. социальные выплаты на члена д/х (рост доходов населения).

Объем итогового набора данных для обучения модели составил 850 наблюдений по 9 показателям.

**Проектирование, обучение и тестирование модели.** Для анализа данных были рассмотрены такие модели машинного обучения как RandomForestRegressor и DecisionTreeRegressor из библиотеки sklearn языка Python. По опыту моделей, построенных экспертами из ФАНУ «Востокгосплан», наибольшую точность показывают именно RandomForestRegressor.

RandomForestRegressor (случайный лес для регрессии) – это алгоритм машинного обучения, который используется для решения задачи регрессии, то есть для предсказания непрерывных числовых значений. Этот алгоритм является частью семейства случайных лесов, которые используются для различных задач машинного обучения, включая классификацию и регрессию [4]. Основные характеристики RandomForestRegressor:

1. ансамбль деревьев решений: RandomForestRegressor создает несколько деревьев решений во время обучения и объединяет их результаты для получения окончательных прогнозов. Это позволяет снизить переобучение и улучшить обобщающую способность модели;

2. случайность: основная идея случайного леса заключается в том, чтобы вводить случайность при обучении каждого дерева. Это делается путем случайного выбора подмножества обучающих данных (bootstrap) и случайного выбора подмножества признаков для поиска наилучшего разделения в каждом узле дерева. Это помогает снизить корреляцию между деревьями и повысить стабильность и обобщающую способность модели;

3. бэггинг: RandomForestRegressor использует метод бэггинга (Bootstrap Aggregating), который заключается в обучении нескольких моделей на разных подмножествах данных и усреднении их прогнозов. Это помогает снизить дисперсию модели и уменьшить вероятность переобучения;

4. важность признаков: RandomForestRegressor предоставляет оценку важности каждого признака. Это позволяет определить, какие признаки наиболее сильно влияют на предсказания модели. Важность признаков вычисляется на основе того, как часто признак используется для разделения данных в деревьях ансамбля;

5. устойчивость к выбросам: RandomForestRegressor обычно хорошо справляется с выбросами и шумом в данных благодаря своей способности усреднять результаты нескольких деревьев;

6. параметры модели: RandomForestRegressor имеет несколько параметров, которые можно настраивать, включая количество деревьев, глубину деревьев, минимальное количество выборок для разделения узла и другие. Эти параметры позволяют более точно настроить модель под конкретную задачу.

Для анализа влияния показателей нижнего уровня на показатели верхнего уровня производилось обучение модели на предоставленных входных данных.

То есть модель учится предсказывать значение показателя верхнего уровня (в данном случае СКР) на основе значений показателей нижнего уровня (например, возраст матери при рождении ребенка и т.д.).

На рис. 2 и 3 представлены соответственно гистограмма, демонстрирующая разницу между истинными и предсказанными моделью значениями СКР, и график отношения истинных значений к предсказанным. Среднеквадратичная ошибка (RMSE): 0,12. Средняя абсолютная ошибка (MAE): 0,09. Коэффициент детерминации ( $R^2$ ): 0,86. На гистограмме отображено 85 тестовых примеров по данным за 2021 год. Из изображенных результатов можно сделать вывод об адекватной работе модели.




Рис. 2. Результат тестирования модели RandomForestRegressor (гистограмма)




Рис. 3. Результат тестирования модели RandomForestRegressor (график отношения истинных значений к предсказанным)

**Исследование предметной области.** Важности показателей нижнего уровня (признаков) отображают то, насколько каждый из них внёс вклад в показатель верхнего уровня. Важности признаков представляют собой числовые значения, где более высокое значение означает более важный признак. В сумме важности дают 1, поэтому могут быть интерпретированы в оценку вклада факторов в рост рождаемости (рис. 4).



Рис. 4. Оценка вклада отдельных групп входных параметров на показатель верхнего уровня

Наиболее значимыми факторами из проведенного анализа являются стимулирование раннего родительства и поддержка молодых семей (отметим, что в России сейчас наблюдается постарение рождаемости и в 2022 году интервал рождений первенца приходился на возраст от 23 до 28 лет. Под «ранним родительством» мы понимаем рождение ребенка в здоровом репродуктивном и социально-экономическом статусе женщины), развитие сельских территорий (исторически сложилось, что в сельских территориях рождаемость выше, соответственно нужно преломлять тренд избыточной урбанизации), укрепление института брака.

**Заключение.** В статье показано, как можно использовать методы машинного обучения, такие как случайные леса, для определения факторов роста рождаемости и дальнейшего их ранжирования по степени вклада в рост. Таким образом, использование алгоритмов машинного обучения для анализа и прогнозирования влияния мероприятий демографической политики на показатели рождаемости может быть эффективным инструментом для разработки и реализации новых национальных проектов, таких как национальный проект «Семья».

## Библиографический список

1. Официальный сайт Правительства России – Михаил Мишустин дал поручения по итогам стратегической сессии, посвящённой новому национальному проекту «Семья». [Электронный ресурс]. Режим доступа: <http://government.ru/news/52327/>.
2. Официальный сайт Правительства России – Михаил Мишустин провёл стратегическую сессию по национальным проектам «Молодёжь и дети» и «Семья». [Электронный ресурс]. Режим доступа: <http://government.ru/news/52118/>
3. Официальный интернет-портал правовой информации – Указ Президента РФ от 07.05.2024 № 309 «О национальных целях развития Российской Федерации на период до 2030 года и на перспективу до 2036 года». [Электронный ресурс]. Режим доступа: <http://pravo.gov.ru>
4. Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. R news, 2(3), 18-22.

## USING MACHINE LEARNING METHODS TO DETERMINE FACTORS INFLUENCING THE BIRTH RATE GROWTH RESULTING FROM THE IMPLEMENTATION OF THE "FAMILY" NATIONAL PROJECT

***Tatiana A. Doroshenko***

Federal Autonomous Scientific Institution "Eastern Center for State Planning",  
127025, Russia, Moscow, Novy Arbat Street, Building 19  
[t.doroshenko@vostokgosplan.ru](mailto:t.doroshenko@vostokgosplan.ru)

***Natalia A. Samsonova***

Federal Autonomous Scientific Institution "Eastern Center for State Planning",  
127025, Russia, Moscow, Novy Arbat Street, Building 19  
[n.samsonova@vostokgosplan.ru](mailto:n.samsonova@vostokgosplan.ru)

The article discusses a model that involves machine learning algorithms used to determine the factors affecting the total fertility rate in the context of the new national project "Family" and demographic policy measures. The research is based on socio-economic development data and includes the evaluation and ranking of factors influencing demographic indicators. Correlation analysis methods and machine learning models, including RandomForestRegressor, are presented for forecasting the impact of proposed measures on achieving national demographic goals.

**Keywords:** machine learning, RandomForestRegressor, fertility factors, total fertility rate



## ДЕМОГРАФИЧЕСКИЕ АСПЕКТЫ ОТКАЗА ОТ КУРЕНИЯ (НА ОСНОВЕ ДАННЫХ СОЦИАЛЬНЫХ МЕДИА И ПРИМЕНЕНИЯ НЕЙРОСЕТЕЙ)

*Калабихина Ирина Евгеньевна<sup>1</sup>, Казбекова Зарина Германовна<sup>1\*</sup>,  
Мошкин Вадим Сергеевич<sup>2</sup>, Колотуша Антон Васильевич<sup>1</sup>,  
Таипов Михаил Маратович<sup>1</sup>, Фаттахов Тимур Асфанович<sup>1</sup>,  
Полетаев Дмитрий Вячеславович<sup>1</sup>, Зайцев Илья Сергеевич<sup>1</sup>*

<sup>1</sup>Московский государственный университет имени М.В. Ломоносова,  
119991, Россия, г. Москва, ул. Ленинские горы, д. 1, стр. 46

<sup>2</sup>Ульяновский государственный технический университет,  
432027, Россия, г. Ульяновск, ул. Северный Венец, д. 32

\*Корреспондирующий автор. kazbekova.zarina@bk.ru

Задачами исследования являются: 1) разработка алгоритма автоматизации доводов пользователей социальных медиа по вопросам в области самосохранительного поведения (мотивация курения либо отказа от курения); 2) структуризация причин (не)отказа от табакокурения русскоязычных пользователей на основе апробации разработанного алгоритма автоматизации доводов (не) бросать курить для аргументации мер демографической политики в перспективе.

**Ключевые слова:** самосохранительное поведение; табакокурение; нейросетевые методы; цифровая демография; машинное обучение; социальные сети; Россия.

**Введение.** Исследования в области цифровой демографии – новый перспективный тренд в общественных и гуманитарных науках. Исследователи в разных странах только начинают разрабатывать алгоритмы извлечения, структурирования, обработки и интерпретации социально-демографических данных о населении по цифровым следам. Использование автоматического извлечения мнений в русскоязычном пространстве Интернета по вопросам изучения демографического поведения актуально в период проведения семейной и демографической политики (2007–2025 гг.), антитабачной политики (особенно активна с 2013 г.) на фоне замедлившегося снижения табакокурения в России (особенно у женщин).

В настоящем исследовании мы используем возможности больших данных и метод машинного обучения для анализа самосохранительного поведения россиян, а именно причин отказа от табакокурения. Основная цель исследования – оценить структуру причин отказа от табакокурения на основе данных социальных сетей с использованием нейросетей. Задачи исследования: 1) разработка алгоритма автоматизации доводов пользователей по вопросам в области самосохранительного поведения (мотивация курения либо отказа от курения) для проведения мониторинга отношения населения к табакокурению; 2) структуризация причин (не)отказа от табакокурения русскоязычных пользователей на ос-

нове апробации разработанного алгоритма автоматизации доводов (не) бросать курить для аргументации мер демографической политики в перспективе.

**Данные и методы.** Мы исследуем структуру доводов (и анти-доводов) отказа от табакокурения с использованием машинного обучения нейронной сети на основе данных платформы YouTube: текстов релевантных комментариев на русском языке. В рамках исследования мы выполняем задачу по разработке и апробации методологии мониторинга двух типов доводов россиян в области самосохранительного поведения. Первый тип – доводы бросить курить. В этой части мы определяем, почему, по мнению россиян, следует бросить курить. Второй тип доводов – доводы не бросать курить. В данном случае мы определяем, почему, по мнению россиян, не следует бросать курить. Применение методов тематического анализа текстов с использованием машинного обучения нейросети позволит выявить, какой фактор отказа от курения имеет больший вес среди пользователей YouTube – забота о собственном здоровье или финансовые издержки курения (дороговизна сигарет); насколько распространены мифы о курении, в частности страх набрать лишний вес из-за отказа от курения.

Среди доводов бросить курить в рамках данного проекта мы выделяем две наиболее распространенные, по нашему мнению, категории: связанные с вредом для здоровья и «вредом» для кошелька курильщика. При этом все остальные доводы мы также учитываем – собирая их в отдельную категорию «иное», что позволяет нам оценивать не только взаимное соотношение выбранных двух категорий, но и их вес в общем массиве доводов.

Наша цель заключалась в том, чтобы обучить нейронную сеть распределять комментарии по выбранным нами классам. Для этого было принято решение проводить классификацию по следующим принципам:

1. Наличие аргумента (любого).
2. Есть ли аргумент в пользу того, чтобы бросить курить ради сохранения здоровья?
3. Есть ли аргумент в пользу того, чтобы бросить курить ради экономии денег?
4. Есть ли аргумент в пользу того, чтобы бросить курить по другой причине?
5. Есть ли аргумент в пользу того, чтобы не бросать курить, чтобы не набрать вес?
6. Есть ли аргумент в пользу того, чтобы не бросать курить по другой причине?

Для решение поставленной задачи было проведено шесть отдельных экспериментов. Для каждого были построены соответствующие модели бинарной классификации в среде Python с использованием PyTorch и библиотек Transformers и ScikitLearn. Обучение проводилось с использованием модели ConversationalRuBERT (<https://huggingface.co/DeepPavlov/rubert-base-cased-conversational>), которая является одной из версий русскоязычной языковой модели RuBERT. Особенность ConversationalRuBERT заключается в том, что она дополнительно обучена на текстах из социальных сетей и пользовательских диалогах.

**Результаты оценки доводов (и анти-доводов) отказа от табакокурения с использованием машинного обучения нейросети.** На рис. 1 представлено общее распределение 8000 аннотированных комментариев по всем классам: 1) «Нет аргумента»; 2) «Есть аргумент» (любой); 3) «За – Здоровье» – аргумент в пользу того, чтобы бросить курить по соображениям, связанным с собственным здоровьем; 4) «За – Деньги» – аргумент в пользу того, чтобы бросить курить по соображениям, связанным с деньгами; 5) «За – Другое» – аргумент в пользу того, чтобы бросить курить по иным соображениям; 6) «Против – Вес» – аргумент в пользу того, чтобы не бросать курить по соображениям, связанным с набором веса; 7) «Против – Другое» – аргумент в пользу того, чтобы не бросать курить по иным соображениям.




Рис. 1. Распределение выборки комментариев по классам

Из выбранного для машинного обучения массива комментариев по теме табакокурения нам удалось вычлениить 20% комментариев с доводами/аргументами – почему человек хочет бросить курить или почему он(а) не хочет этого делать. Как мы и предполагали, основные аргументы «за» отказ от курения – страх/забота о собственном здоровье и желание экономить бюджет семьи или личные деньги. Аргументы «против» отказа от курения содержат заметную часть, основанную на страхе о наборе веса. Гипотеза подтвердилась, такая причина встречается достаточно – около 22% анти-доводов.

**Заключение.** По нашим данным, в аргументированных комментариях против курения преобладает мотив отказа по соображениям здоровьесбережения, по сравнению с аргументом о сбережении денежных средств. Для людей, поддерживающих курение, борьба с лишним весом не является ведущим мотивом. Однако этот мотив существует и выделен четко. Точность предсказания классов в среднем превышает 85%, что свидетельствует о достаточной надёжности полученных результатов.

Разработанный нами автоматический алгоритм определения наличия довода по поводу отказа от курения и автоматической классификации доводов по указанным классам можно применять с целью мониторинга мнений пользователей русскоязычных социальных сетей по вопросам отказа от курения.

**Ограничения и перспективы исследования.** Наш подход к классификации доводов отказа от традиционного курения табака был основан на изучении комментариев в социальных сетях по аргументам отказа от курения на ос-

нове использования методов машинного обучения для автоматического распознавания классифицированных доводов и их наличия. Ограничения исследования связаны со спецификой используемых данных. Эмпирически мы выявили, что YouTube содержал большее количество релевантных нашей задаче комментариев, в связи с чем в качестве источника данных мы выбрали именно его. Однако среди минусов YouTube как источника данных для решения целей настоящего исследования, мы выделяем, во-первых, отсутствие данных о социально-демографических характеристиках индивида, что мешает нам на первой стадии исследования без дополнительных существенных усилий определить пол и возраст комментаторов, что важно для социально-демографической политики. Во-вторых, при наборе даже больших массивов комментариев мы сталкиваемся с невозможностью получить репрезентативный срез всего общества таким методом. И структура пользователей социальной сети, и структура авторов набора комментариев по ключевым словам могут не совпадать со структурой населения России. Тем не менее, такой источник данных служит богатым дополнением к имеющимся редким данным социологических опросов. Их можно получать постоянно, и цена вопроса не такая высокая. Выход в контексте улучшения интерпретации результатов подобных исследований состоит в комбинировании разных источников данных, во взаимной «помощи» разных источников данных (на стадии формулировки гипотез, верификации результатов и пр.).

Перспективы развития исследования о факторах отказа от табакокурения состоят из нескольких направлений. Во-первых, следующий шаг будет нацелен на исследование демографических характеристик людей с разными аргументами по этому вопросу с использованием лингвистических алгоритмов и больших языковых моделей. Научно обоснованная политика на основе доказательного подхода должна опираться на детализированные по демографическим критериям данные. Во-вторых, датасет, помимо самого комментария, содержит столбец с информацией о дате публикации комментария. На данном этапе эту информацию мы не использовали. Однако в дальнейшем она может послужить для оценки динамики структуры доводов. Как во времени менялась доля основных доводов и анти-доводов, как это связано с этапами антитабачной политики, которая проводится в России. В-третьих, мы планируем изучить способы отказа от традиционного курения (в том числе, переход на электронные сигареты и пр.) среди разных демографических групп. Такая работа позволит уточнить целевые группы для антитабачной политики и разработать дополнительные рекомендации. В-четвертых, мы планируем совершенствовать методологию – использовать и в этой теме гибридные нейросети в классификации высказываний пользователей социальных сетей, что должно повысить точность классификации высказываний.

**Поддержка исследования.** Исследование выполнено в рамках НИР «Воспроизводство населения в социально-экономическом развитии» 122041800047-9.

# DEMOGRAPHIC ASPECTS OF SMOKING CESSATION (BASED ON SOCIAL MEDIA DATA AND THE USE OF NEURAL NETWORKS)

*Irina E. Kalabikhina<sup>1</sup>, Zarina G. Kazbekova<sup>1\*</sup>, Vadim S. Moshkin, Anton V. Kolotusha<sup>1</sup>,  
Mikhail M. Taipov<sup>1</sup>, Timur A. Fattakhov<sup>1</sup>, Dmitriy V. Poletaev<sup>1</sup>, Ilya S. Zaitsev<sup>1</sup>*

<sup>1</sup>Lomonosov Moscow State University,  
119991, Russia, Moscow, Leninskie Gory, 1/46  
<sup>2</sup>Ulyanovsk State Technical University  
432027, Russia, Ulyanovsk, st. Severny Venets, 32  
\* Corresponding author. kazbekova.zarina@bk.ru

The objectives of the study are: 1) development of an algorithm for automating arguments of social media users on issues in the field of self-preservation behavior (motivation to smoke or quit smoking); 2) structuring the reasons for (not) quitting smoking of Russian-speaking users based on testing the developed algorithm for automating arguments (not) to quit smoking for arguing demographic policy measures in the future.

**Keywords:** self-preservation behavior; smoking; neural network methods; digital demography; machine learning; social networks; Russia.

УДК 004.032.26

# МЕТОД МАШИННОГО ОБУЧЕНИЯ НА ОСНОВЕ СГЕНЕРИРОВАННЫХ АСТРОФИЗИЧЕСКИХ ДАННЫХ ДЛЯ ОПРЕДЕЛЕНИЯ КОЛИЧЕСТВА СПИРАЛЕЙ ГАЛАКТИК

**Яваев Рамиль Рифатович**

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
ramilavaev14@gmail.com

**Поляков Максим Валентинович**

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
m.v.polyakov@volsu.ru

В данной работе представлена модель свёрточной нейронной сети для количественной оценки спиральных рукавов галактик, обученной на наборе данных, который включает в себя реальные и сгенерированные с помощью разработанного программного обеспечения изображения спиральных галактик.

**Ключевые слова:** спиральные галактики, синтетические данные, нейросетевые технологии, астрофизика, анализ данных.

**Введение.** Большая часть известных на данный момент галактик имеют спиральную структуру с выраженными спиральными рукавами [1]. Спиральные рукава характеризуются повышенной концентрацией газа и активным звездо-

образованием. Использование машинного обучения для классификации спиральных галактик по количеству рукавов может помочь в составлении данных для исследований, связанных с вопросом их формирования.

В одной из работ была предпринята попытка автоматизации количественной оценки спиральных рукавов галактик с помощью модели сверточной нейронной сети, обученной на данных, взятых с помощью открытого интернет-проекта Galaxy Zoo [2], но после обучения модель показала неудовлетворительный уровень точности предсказаний количества спиральных рукавов. Низкий показатель точности был вызван высоким уровнем шума исходных изображений, используемых для обучения модели. Исходя из вышеописанного, было принято решение обучить модель, опираясь на использование сгенерированных астрофизических данных.

**Постановка задачи и формирование набора данных.** Для формирования обучающей выборки использовались классифицированные данные, взятые из открытого интернет-проекта Galaxy Zoo 2 [2], который, в свою очередь, использует данные из SDSS Data Release [3]. Изображения отбирались по условиям, основанным на информации из статьи [4].

Сама выборка состоит из пяти классов, характеризующих определенное количество спиральных рукавов: 1, 2, 3, 4, 5+, при этом класс, к которому относится изображение галактики, определялся на основе ответа на вопрос о числе рукавов с преобладающим значением доли голосов.

Также были аугментированы изображения многорукавных галактик с целью увеличения обучающей выборки вышеупомянутых классов.

Кроме реальных данных, также использовались данные, полученные искусственным путем. Обуславливается это тем, что синтетические астрофизические данные можно использовать для повышения общего качества обучающей выборки, для поиска взаимосвязей между структурными особенностями галактик и параметрами их моделирования, а также для тестирования архитектур нейронных сетей на чистых данных, как, например, в статье [5].

Для генерации синтетических обучающих данных, была разработана программа на языке программирования Python с использованием библиотеки PyOpenGL для визуализации смоделированной галактики на 3D-сцене.

Генерация изображения галактики проходила в несколько этапов:

1. Рандомизация начальных параметров генерации;
2. Генерация центра галактики;
3. Генерация галактического диска;
4. Генерация балджа при удовлетворении условий его генерации;
5. Генерация спиральных рукавов, точки которых вычислялись по формуле логарифмической спирали в декартовой системе координат;
6. Сохранение полученной 3D-сцены в виде изображения, сглаженного с помощью размытия Гаусса.

В ходе работы программы было получено 11091 изображение спиральных галактик размером  $212 \times 212$  пикселей формата .jpg, сбалансированно разбитых на пять каталогов, каждый из которых соответствует классу количественной

оценки спиральных рукавов: 1, 2, 3, 4 и 5+. На рис. 1 представлены примеры изображений, сгенерированных программой.

### **Проектирование, обучение и тестирование свёрточной нейронной сети.**

Программный код для обучения модели нейронной сети написан на языке программирования Python с использованием API TensorFlow и Keras. За основу архитектуры модели была взята архитектура VGG Net [6].

Архитектура модели включает в себя входной слой, получающего изображение галактики, нескольких свёрточных и полносвязных слоев для выделения и классификации признаков, субдискретизирующих слоев для уменьшения размерности изображения и вероятности переобучения, а также выходного слоя, возвращающий предсказание количества спиральных рукавов.




Рис. 1. Примеры изображений галактик, сгенерированных с помощью разработанной программы: слева двухрукавная галактика с балджем, справа четырехрукавная галактика без балджа

Обучение производилось с использованием 17375 обучающих и 5792 тестовых изображений. Для проверки итоговой точности предсказания обученной модели использовалось 500 валидационных изображений.

После обучения модели в течении 20 эпох точность на обучающей и тестовой выборках составила 81.33% и 73.70% в соответственно. В сравнении с результатом предыдущей работы, в которой точность модели составляла 68.83% на обучающей и 63.27% на тестовой выборках соответственно, заметно улучшение качества предсказаний.

На рис. 2 приведены две матрицы неточностей модели. Справа представлена матрица модели, обученной сугубо на реальных данных. Слева – обученная с использованием синтетических данных.




Рис. 2. Матрицы неточностей модели свёрточной нейронной сети, обученной на разных наборах данных

**Заключение.** В результате исследования обучена модель свёрточной нейронной сети для количественной оценки спиральных рукавов. Спроектирована и реализована программа для генерации данных, представляющих собой изображения спиральных галактик. Полученные изображения использовались в качестве обучающих данных.

Обученная модель способна выполнять количественную оценку спиральных рукавов галактик с удовлетворительным уровнем точности. Использование синтетических астрофизических данных в обучающей выборке оказало положительное воздействие на конечную точность количественной оценки.

Исходя из результатов исследования можно утверждать, что использование синтетических данных при обучении модели не оказывает негативное влияние на итоговую точность. Эту особенность можно использовать в тех случаях, когда реальных данных не хватает для формирования обучающей выборки.

## Библиографический список

1. Mihalas D., Binney J. Galactic Astronomy: Structure and Kinematics // W.H. Freeman. – 1981.
2. Galaxy Zoo. [Электронный ресурс] Режим доступа: <https://www.zooniverse.org/projects/zookeeper/galaxy-zoo>
3. Galaxy Zoo 2: detailed morphological classifications for 304,122 galaxies from the Sloan Digital Sky Survey / K. Willett [идр.] // Monthly Notices of the Royal Astronomical Society. – 2013 – pp. 2835-2860.
4. R. E. Hart et al., Galaxy Zoo: comparing the demographics of spiral arm number and a new method for correcting redshift bias // Monthly Notices of the Royal Astronomical Society, Vol. 461, № 4, pp. 3663-3682.
5. Bekki, Kenji. Quantifying the fine structures of disk galaxies with deep learning: Segmentation of spiral arms in different Hubble types // Astronomy and Astrophysics. – 2021. – Vol. 647. – P. 14.
6. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition // arXiv 1409.1556. – 2014.



# MACHINE LEARNING METHOD BASED ON GENERATED ASTROPHYSICAL DATA TO DETERMINE THE NUMBER OF SPIRALS OF GALAXIES

***Yavaev Ramil Rifatovich***

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
ramilavaev14@gmail.com

***Polyakov Maxim Valentinovich***

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
m.v.polyakov@volsu.ru

This article presents a convolutional neural network model for quantifying spiral arms of galaxies, trained on a dataset that includes real and spiral galaxy images generated with the developed software.

**Keywords:** spiral galaxies, synthetic data, neural network technologies, astrophysics, data analysis.

УДК 004.032.26

## ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ АСТРОМЕТРИЧЕСКИХ ДАННЫХ КОСМИЧЕСКОГО ТЕЛЕСКОПА GAIA

***Резанов Кирилл Владимирович***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
prib-211\_349298@volsu.ru

***Поляков Максим Валентинович***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
m.v.polyakov@volsu.ru

В работе рассмотрено применение астрометрических данных в науке, описан математический аппарат для обработки данных движения звезд кластеров Большого Магелланова Облака на основе математической статистики. Также приведены результаты экспериментов и выявлен звездный кластер, который потенциально может иметь внегалактическое происхождение.

**Ключевые слова:** интеллектуальный анализ данных, телескоп Gaia, кластеры Большого Магелланова Облака, отклонение движения.

**Введение.** Данные, полученные астрометрическими источниками, являются важными для понимания эволюции и истории космических структур, строения космических тел и изучения некоторых физических явлений. Эти данные также могут иметь большие объемы, из-за чего поиск нужных данных из всего массива может быть затруднен.

С помощью данных, полученных астрофизическими, астрометрическими и фотометрическими источниками была построена трехмерная карта нашей галактики, которая содержит более 1.8 миллиарда объектов [1]. С помощью анализа движения звезд возможно определение их внегалактического происхождения [2]. С помощью телескопа Джеймса Уэбба планируется изучение формирования первых галактик во Вселенной [3].

Одним из способов обработки астрометрических данных является интеллектуальный анализ. Интеллектуальный анализ данных – процесс обнаружения пригодных к использованию сведений в крупных наборах данных. Интеллектуальный анализ включает методы машинного обучения, математической статистики и запросы к базам данных. Для интеллектуального анализа данных необходимо выявить проблему (задачу), выбрать и подготовить данные, создать систему для их анализа.

Одним из источников астрометрических данных является космический телескоп Gaia. В третьем релизе данного телескопа появились данные о звездах за пределами нашей галактики, в частности, данные о движении звезд в Большом Магеллановом Облаке. Большое Магелланово Облако – галактика-спутник Млечного Пути, которая также имеет спутники, однако взаимодействие было замечено только с Малым Магеллановым Облаком. С помощью анализа движения звезд возможно определить вероятность внегалактического происхождения кластеров звезд в составе галактики.

Поэтому для данной работы была поставлена следующая цель: создание программы, которая будет выявлять отклонение собственного движения звезд некоторых кластеров Большого Магелланова Облака от окружающих их звезд с использованием нейронной сети, а также будет визуализировать обработанные данные.

**Постановка задачи.** Для данной работы была выбрана нейронная сеть на основе перцептронов, которая включает входной слой, скрытый слой и выходной слой. Для входного и скрытого слоя было решено использовать по 100 нейронов. Нейроны входного слоя принимают значения движения 50 звезд некоторого кластера БМО и 50 окружающих их звезд. Это позволяет уменьшить влияние шумов из-за малого количества входных данных, а также позволяет разбить данные об одном кластере на несколько сетов данных для увеличения тестовой и обучающей выборки. В качестве активационной функции при выводе используется сигмоида, так как она позволяет обрабатывать данные в значениях от 0 до 1, что необходимо для бинарной классификации, которая происходит в данной работе. Также используется смещение (bias), которое позволяет более точно производить классификацию. В качестве выходного слоя имеется один нейрон, который выводит значения от 0 до 1, где число близкое к 0 значит, что кластер был сформирован в галактике, а число близкое к 1 сигнализирует о возможном внегалактическом происхождении кластера.

Данные были получены с помощью запросов к базе данных Gaia, также для получения центров звездных скоплений и центра БМО использовалась астрономическая база данных SIMBAD. На выборку звезд были наложены следующие фильтры:

- 1) для всех звезд галактики выбирались те, что лежат в радиусе 5 градусов от центра БМО. Центр галактики был получен с помощью SIMBAD и равен  $(RA, DEC) = (80.8942, -69.756)$  в международной небесной системе координат;
- 2) звезды без данных о собственном движении не использовались;
- 3) использовались только звезды синего спектра;
- 4) звезды с параллаксом больше 0.1 мс не использовались;
- 5) звезды со значением нормированной ошибки веса единицы измерения (ruwe) больше 1.4 не использовались.

### **Настройка параметров нейронной сети и обработка выборок данных.**

Для нейронной сети необходимо было подобрать оптимальную скорость обучения. В ходе тестирования было выявлено, что значение для скорости обучения равное 0.1 не подходит (рис.1).




Рис. 1. График, показывающий корень среднеквадратичного отклонения вычисленных значений от ожидаемых значений обучающей выборки в зависимости от эпохи обучения нейронной сети при скорости обучения равной 0.1

На графике видно, что ошибка с течением времени не уменьшалась, а даже наоборот увеличивалась. Для данного значения скорости обучения проводились тесты вплоть до миллиона эпох, однако результаты обучения оставались те же. Сходимости нейронной сети не происходило, поэтому было необходимо подбирать другие значения для скорости обучения. После этого проводились тесты для скорости обучения равной 0.01 и 0.001 значение ошибки для них были идентичными, однако скорость работы сети для 0.01 происходило быстрее, из-за чего было выбрано это значение. График для скорости обучения 0.01 представлен (рис. 2).

В ходе работы были созданы тестовая и обучающая выборки. Процентное распределение выборок представлено (Рис. 3).

Тип 0 на диаграмме – сетки данных кластеров, которые всегда являлись членами БМО, тип 1 – те кластеры, которые имеют потенциальное внегалактическое происхождение. Как видно из диаграмм сетов данных с кластерами типа 1 в разы меньше, чем данных с типом 0, это связано с тем, что большая часть кластеров является элементами БМО. В исходных данных количество кластеров типа 1 занимает примерно 5-10% от их общего числа. Было принято решение ограничить процент кластеров типа 0 в обучающей выборке, так как их большое содержание в ней может понизить точность определение кластеров типа 1. В тестовой выборке кластеры типа 0 также были ограничены, но в меньшей степени для увеличения общей выборки.




Рис. 2. График, показывающий корень среднеквадратичного отклонения вычисленных значений от ожидаемых значений обучающей выборки в зависимости от эпохи обучения нейронной сети при скорости обучения равной 0.01




Рис. 3. Круговые диаграммы с процентным распределением сетов данных разных типов кластеров в обучающей и тестовой выборке

**Результаты экспериментов.** В процессе обучения и использования нейронной сети были построены графики точности для тестовой выборки и меры ошибки для обучающей (рис. 4).

Графики показывают точность определения тестовых наборов данных на нейронной сети, обученной со скоростью обучения 0.01. На графиках видно, что нейронная сеть точно справляется со всеми сетами данных для кластеров типа 0, однако с течением времени точность для кластеров типа 1 падает. Также мы видим сходимость нейронной сети на первом графике, где значение ошибки практически достигло 0. В качестве меры ошибки используется метрика корня среднеквадратичного отклонения (RMSE).




Рис. 4. Слева сверху график меры ошибки для обучающей выборки, снизу общая точность определения выборки, справа сверху точность для кластеров-членов БМО, снизу точность для потенциально внегалактических кластеров, графики построены для скорости обучения 0.01

Уменьшение точности для кластеров типа 1 может происходить по нескольким причинам, например:

- 1) малое число кластеров типа 1 в обучающей выборке;
- 2) малая выборка в целом;
- 3) различия полученных данных в ходе запросов к БД Gaia с исследованиями, на которые опираются выборки.

**Заключение.** В результате выполнения данной работы была спроектирована нейронная сеть, которая анализирует движение звезд некоторых кластеров БМО. Работа нейронной сети была проверена в ходе экспериментов на данных из других исследований. Была достигнута относительно большая точность определения типов кластеров, несмотря на малую обучающую выборку данных.

В ходе проведения экспериментов было выявлено отклонение звезд кластеров от окружающих их звезд, которые соответствовали результатам в похожих исследованиях практически для всех данных.

## Библиографический список

1. Gaia Data Release 3. Summary of the content and survey properties / A. Vallenari, T. Prusti, C. Babusiaux [et al.]. – Текст : непосредственный // *Astronomy & Astrophysics*. – 2023, – Vol. 674. – A1.
2. The merger that led to the formation of the Milky Way's inner stellar halo and thick disk. / A. Helmi, C. Babusiaux, H. H. Koppelman [et al.]. – Текст : непосредственный // *Nature*. – 2018. – Vol. 563, №2. – P. 85-88.
3. The James Webb space telescope mission / P. Jonathan, C. John, A. Randy [et al.] – 2023. – arXiv: 2304.04869 [astro-ph.IM] URL: <https://arxiv.org/abs/2304.04869> (дата обращения: 09.04.2024). – Режим доступа: свободный.
4. Metallicities and ages for star clusters and their surrounding fields in the Large Magellanic Cloud / W. Narloch, G. Pietrzyński, W. Gieren [et al.]. – Текст : непосредственный // *Astronomy & Astrophysics*. – 2022. – Vol. 666. – A80.

## INTELLIGENT ANALYSIS OF ASTROMETRIC DATA FROM THE GAIA SPACE TELESCOPE

***Rezanov Kirill Vladimirovich***

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
[prib-211\\_349298@volsu.ru](mailto:prib-211_349298@volsu.ru)

***Polyakov Maxim Valentinovich***

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
[m.v.polyakov@volsu.ru](mailto:m.v.polyakov@volsu.ru)

The article considers the application of astrometric data in science, describes the mathematical apparatus for processing the data on the motion of stars of the clusters of the Large Magellanic Cloud on the basis of mathematical statistics. The results of experiments are also given and a star cluster is identified that could potentially have an extragalactic origin.

**Keywords:** intelligent data analysis, Gaia telescope, clusters of the Large Magellanic Cloud, motion deviation.

## **ВЛИЯНИЕ РАЗМЕРА ОБУЧАЮЩЕЙ ВЫБОРКИ НЕЙРОСЕТИ НА ТОЧНОСТЬ ОПРЕДЕЛЕНИЯ ПАРАМЕТРОВ ГИДРАВЛИЧЕСКОГО СОПРОТИВЛЕНИЯ В МОДЕЛИ МЕЛКОЙ ВОДЫ**

***Кликунова Анна Юрьевна***

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

***Хоперсков Александр Валентинович***

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

Работа посвящена разработке метода нахождения параметров гидравлического сопротивления потока воды в модели мелкой воды с использованием интеграции методов гидродинамического моделирования и машинного обучения. Численная гидродинамическая модель речной системы содержит четыре свободных параметра, определение которых основано на сравнении результатов моделирования с данными измерений на трех гидрологических станциях. Расчет этих величин проводится с использованием нейронной сети с архитектурой LSTM.

**Ключевые слова:** нейронная сеть, LSTM, модель мелкой воды, объем обучающей выборки, гидравлическое сопротивление.

**Введение.** Решение широкого круга прикладных задач требует численного моделирования гидрологического режима речных систем с учетом конкретных условий состояния природной системы [1–6]. В связи с необходимостью проводить многочисленные расчеты для больших территорий на длительных интервалах времени (порядка года и больше), как правило, используются гидродинамические модели в приближении мелкой воды [7]. Важным компонентом таких моделей является гидравлическое сопротивление, которое в большинстве исследований описывается коэффициентом Маннинга. Мы предлагаем рассматривать гидравлическое сопротивление в виде суммы двух факторов, учитывающих как шероховатость подстилающей поверхности (стандартный коэффициент Маннинга) [7], так и турбулентную вязкость, влияние которой доминирует на больших глубинах [8, 9]. Отдельное выделение влияния турбулентной вязкости на поток обеспечивает лучшее согласие с данными измерений на гидрологических станциях.

Целью работы является решение обратной задачи, которая подразумевает нахождение входных параметров для моделирования. В качестве полигона исследования рассматривается северный участок Нижней Волги. Согласование временных рядов гидрологических данных с соответствующими рядами, полученными по результатам гидродинамического моделирования, позволяет вычислять свободные параметры численной модели. Использование нейросетевого моделирования оказывается эффективным методом решения такой задачи.

**Постановка задачи и результаты.** Исследуемый нами участок реки Волга имеет длину около 100 км и расположен ниже плотины Волжской ГЭС. Гидрологический режим реки, а также Волго-Ахтубинской поймы, расположенной в междуречье Волги и Ахтубы, полностью определяется попуском воды через плотину. На данном участке Волги расположено три измерительные станции, на которых ежедневно фиксируется уровень воды. При моделировании динамики поверхностных вод в рамках модели мелкой воды (Сен-Венана) стандартно учитывается только вклад в сопротивление из-за эффективной шероховатости дна [7, 10]:

$$\vec{f}^{(M)} = g \frac{n_M^2 |\vec{u}|}{H^{4/3}} \vec{u}, \quad (1)$$

где  $H(x, y, t)$  – глубина слоя воды,  $\vec{u}(x, y, t)$  – скорость,  $n_M$  – коэффициент Маннинга. Мы обобщаем модель (1) дополнительным учетом турбулентной вязкости, так что удельная сила гидравлического сопротивления определяется двумя слагаемыми:

$$\vec{f}^{(HR)} = \vec{f}^{(M)} + \vec{f}^{(turb)} = g \frac{n_M^2 |\vec{u}|}{H^{4/3}} \vec{u} + \alpha H^\gamma |\vec{u}|^{1-\gamma} \vec{u}. \quad (2)$$

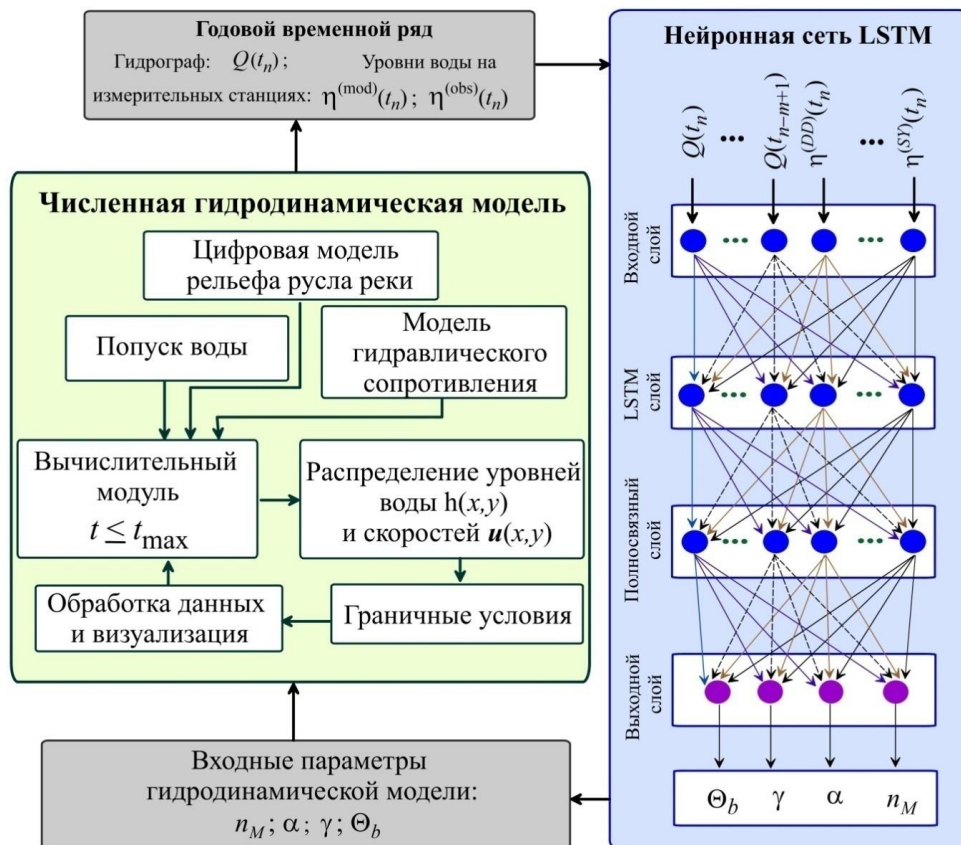


Рис. 1. Общая структура программного модуля для определения параметров гидравлического сопротивления реки на основе сочетания гидродинамического моделирования и машинного обучения

Величина  $\vec{f}^{(HR)}$  зависит от глубины  $H(x, y, t)$ , скорости  $\vec{u}(x, y, t)$  и трех свободных параметров  $n_M, \alpha, \gamma$ , которые подлежат определению. Четвертый свободный параметр  $\Theta_b$  задает граничные условия на выходе воды из вычислительной области.



Рис. 1 показывает общую структуру программного обеспечения, которое разделено на три основных модуля. Первый модуль подготавливает все необходимые входные пространственные и временные характеристики. Вычислительный гидродинамический модуль EcoGIS-Simulation [7, 11] основан на численном алгоритме CSPH-TVD [12, 13]. Все высокопроизводительные вычисления выполнялись на графических процессорах с использованием NVIDIA CUDA [14]. Для вычисления значений  $n_M$ ,  $\alpha$ ,  $\gamma$ ,  $\Theta_b$  используется нейронная сеть Long short-term memory. Такой выбор связан с наличием запаздывания физических процессов в реальной системе, что учитывается заданием длины памяти в NN LSTM.

Численное моделирование дает наборы временных рядов уровней воды  $\eta^{(mod)}(t)$ , которые должны быть согласованы с измеренными  $\eta^{(obs)}(t)$  на всех трех гидропостах.

Мы строим две серии расчетов, содержащих 16 и 32 вычислительных эксперимента с различными наборами входных параметров. Для двух размеров обучающей и тестовой выборки получены наборы четырех параметров гидравлического сопротивления, которые были использованы для валидации численной модели (табл.).

Таблица

**Результаты оценки свободных параметров**

Количество гидродинамических экспериментов	$n_M$	$\alpha$	$\gamma$	$\theta$
16	0.01530	$1.535 \cdot 10^{-4}$	0.5281	$0.624 \cdot 10^{-5}$
32	0.01531	$1.535 \cdot 10^{-4}$	0.5245	$0.623 \cdot 10^{-5}$




Рис. 2. Разность между рядами, измеренными на гидропостах и модельными уровнями воды в течение 2022 года (красные сплошные линии для 16 численных гидродинамических экспериментов, синие пунктирные – для 32): а) гидропост нижний бьеф Волжской ГЭС, б) гидропост речной порт г. Волгоград, в) гидропост пгт. Светлый Яр

**Заключение.** Предлагаемый метод валидации численных гидродинамических моделей обеспечивает удовлетворительное воспроизведение гидрологических данных, измеряемых на гидропостах для реки Волга ниже дамбы Волжской ГЭС. Нейронная сеть с памятью позволяет восстановить входные свободные параметры гидродинамической модели по небольшому набору вычислительных экспериментов, что существенно снижает вычислительные затраты по сравнению с традиционными методами типа градиентного спуска. Планируется провести тестирование метода для других водных объектов.

Работа выполнена по гранту РНФ №23-71-00016 (<https://rscf.ru/project/23-71-00016/>) с использованием оборудования Центра коллективного пользования сверхвысокопроизводительными вычислительными ресурсами МГУ имени М.В. Ломоносова.

### Библиографический список

1. Isaeva I.I., Voronin A.A., Khoperskov A.V., Kharitonov M.A. Modeling the Territorial Structure Dynamics of the Northern Part of the Volga-Akhtuba Floodplain // *Computation*. – 2022. – Vol. 10(4). – id.62. <https://doi.org/10.3390/computation10040062>
2. Voronin A.A., Vasilchenko A.A., Klikunova A.Yu., Vatyukova O.Yu., Khoperskov A.V. The problem of safe evacuation of large floodplains population during flooding // *Advances in Systems Science and Applications*. – 2022. – Vol. 22(4). – P. 65–78. <https://doi.org/10.25728/assa.2022.22.4.1310>
3. Agafonnikova E.O., Klikunova A.Yu., Khoperskov A.V. A computer simulation of the Volga river hydrological regime: a problem of water-retaining dam optimal location // *Bulletin of the South Ural State University, Series: Mathematical Modelling, Programming and Computer Software*. – 2017. – Vol. 10(3). – P. 148–155. <https://doi.org/10.14529/mmp170313>
4. Кликунова А.Ю., Дьяконова Т.А., Агафонникова Е.О., Маковеев И.С., Корнаухова М.А., Радченко В.П. Моделирование затоплений населенных пунктов в период весеннего паводка // *Математическая физика и компьютерное моделирование*. – 2021. – Т.24, №3. – С. 63–72.
5. Сухинов А.И., Чистяков А.Е., Сидорякина В.В., Кузнецова И.Ю. Численное моделирование последствий дампинга при проведении дноуглубительных работ в прибрежных морских системах // *Математическая физика и компьютерное моделирование*. – 2023. – Том 26, № 3. – С. 37-52
6. Белоконь А.Ю., Фомин В.В. Характеристики штормового волнения в бухте Ласпи (Черное море) по результатам численного моделирования // *Экологическая безопасность прибрежной и шельфовой зон моря*. – 2024. – № 2. – С. 60-75.
7. Khrapov, S.S.; Khoperskov, A.V. Application of Graphics Processing Units for Self-Consistent Modelling of Shallow Water Dynamics and Sediment Transport // *Lobachevskii Journal of Mathematics*. – 2020. – Vol. 41(8). – P. 1475–1484. <https://doi.org/10.1134/S1995080220080089>
8. Khoperskov A.V., Khrapov S.S., Klikunova A.Yu., Popov I.E. Efficiency of Using GPUs for Reconstructing the Hydraulic Resistance in River Systems Based on Combination of High Performance Hydrodynamic Simulation and Machine Learning // *Lobachevskii Journal of Mathematics*. – 2024. – Vol.45, No.7. – P.3094–3105.
9. Klikunova A.Yu., Polyakov M.V., Khrapov S.S. Khoperskov A.V. Problem of building high-quality predictive model of river hydrology: the combined use of hydrodynamic simulations and intelligent computing // *Communications in Computer and Information Science*. – 2023. – Vol. 1909. – P. 191–205. [https://doi.org/10.1007/978-3-031-44615-3\\_13](https://doi.org/10.1007/978-3-031-44615-3_13)
10. de Paiva, R.C.D., Buarque, D.C., Collischonn, W., Bonnet, M.-P., Frappart, F., Calmant, S., Mendes, C.A.B. Large-scale hydrologic and hydrodynamic modeling of the Amazon River basin // *Water Resources Research*. – 2013. Vol. 49(3). – P. 1226–1243. <https://doi.org/10.1002/wrcr.20067>
11. Khrapov S., Agafonnikova E., Potaptseva P., Makoveev I., Klikunova A. EcoGIS-Simulation Software for riverbed sediments modeling // *E3S Web of Conferences*. – 2023. – Vol. 411, id.02005. – P. 1–6. <https://doi.org/10.1051/e3sconf/202341102005>
12. Khrapov S.S. Numerical modeling of self-consistent dynamics of shallow waters, traction and suspended sediments: II. Study of the transverse deformations of the channel and the redistribution of water

discharges along the branches of the Volga River during industrial sand mining. Mathematical Physics and Computer Simulation. – 2022. – Vol. 25(4). – P. 52–65. <https://doi.org/10.15688/mpcm.jvolsu.2022.4.5>

13. Arkhipov B., Rychkov S., Shatrov A. High-Performance Calculations for River Floodplain Model and Its Implementations // Communications in Computer and Information Science. – 2019. – P. 211–224. [https://doi.org/10.1007/978-3-030-28163-2\\_15](https://doi.org/10.1007/978-3-030-28163-2_15)

14. Dyakonova T., Khoperskov A., Khrapov S. Numerical Model of Shallow Water: The Use of NVIDIA CUDA Graphics Processors // Communications in Computer and Information Science. – 2016. – Vol. 687. – P. 132–145. [https://doi.org/10.1007/978-3-319-55669-7\\_11](https://doi.org/10.1007/978-3-319-55669-7_11)

## NEURAL NETWORK SYSTEM FOR PREDICTING THE VALUE OF REAL ESTATE IN THE PRIMARY HOUSING MARKET

*Anna Yu. Klikunova*

Volgograd State University,  
Prospect Universitetsky 100, Volgograd, Russia, 400062  
[klikunova@volsu.ru](mailto:klikunova@volsu.ru)

*Alexander V. Khoperskov*

Volgograd State University,  
Prospect Universitetsky 100, Volgograd, Russia, 400062  
[khoperskov@volsu.ru](mailto:khoperskov@volsu.ru)

The work is aimed at developing a method for calculating the parameters of hydraulic resistance to water flow in a shallow water model using the integration of hydrodynamic modeling and machine learning methods. The numerical hydrodynamic model of the river system contains four free parameters, the determination of which is based on a comparison of the modeling results with measurement data at three hydrological stations (gauging stations). The calculation of these values is carried out using a neural network with LSTM architecture.

**Keywords:** neural network, LSTM, shallow water model, training sample size, hydraulic resistance.

УДК 004.032.26

## КЛАССИФИКАЦИЯ ГАЛАКТИК ПО МОРФОЛОГИЧЕСКИМ ТИПАМ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

*Панафидин Михаил Николаевич, Бутенко Мария Анатольевна*

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
[istb-211\\_496181@volsu.ru](mailto:istb-211_496181@volsu.ru), [maria\\_butenko@volsu.ru](mailto:maria_butenko@volsu.ru)

В статье представлено решение задачи автоматизации процесса классификации галактик по их морфологическим типам с применением нейросетевых технологий. Проведен анализ влияния состава обучающей выборки на результаты распознавания. Представлены результаты классификации для сбалансированной и несбалансированной выборки, а также дальнейшие пути улучшения качества модели.

**Ключевые слова:** нейросетевые технологии, морфологический тип галактики, задача классификации, Sloan Digital Sky Survey (SDSS).

**Введение.** В астрономии, как и во многих областях науки и техники, наблюдаются высокие темпы роста количества данных, получаемых с различных приборов. В указанной сфере науки это данные наблюдений различных наземных и космических аппаратов. В таких условиях применение «ручной» обработки данных становится крайне неэффективным. Необходимо применение методов, автоматизирующих решение задач, возникающих перед астрономами. Одной из таких задач является классификация объектов по их изображениям. В текущее время для решения задач этого класса эффективно используются искусственные нейронные сети [1-6]. Мы в своей работе также рассмотрели решение с применением нейросетевых технологий задачи морфологической классификации галактик. Классификация галактик по морфологическим типам является первым и обязательным этапом для дальнейшего более глубокого изучения процессов, происходящих внутри галактик. Также такая первичная классификация в автоматизированном режиме дает астрономам возможность быстро получать большие объемы информации, которую можно использовать для статистической обработки.

С ростом объемов доступных данных и совершенствованием технологий анализа информации возникают новые возможности для более точного и полного изучения структуры и свойств галактик. Выявление таких морфологических особенностей как галактические бары и различия в спиральной структуре дисковых галактик также становится возможным [7].

**Постановка задачи и формирование набора данных для обучения.** В представленной работе для решения задачи классификации были использованы данные, полученные из проекта GalaxyZoo [8] – самого масштабного проекта гражданской науки по морфологической классификации галактик. Этот проект использовал для своей работы изображения SDSS (Sloan Digital Sky Survey) [9]. Данные, полученные от участников проекта, прошли многоэтапную обработку. В результате был сформирован набор данных, который можно использовать для обучения нейросетевых систем различной архитектуры.

Для создания нейросетевой системы были выделены три класса галактик: спиральные, эллиптические и неправильные. В файле, содержащем данные из каталога GalaxyZoo, эти классы соответствуют столбцам SPIRAL, ELLIPTICAL и UNCERTAIN, соответственно. Для обучения было выбрано 30000 объектов, находившихся в каталоге GalaxyZoo первыми.

Для проведения классификации галактик были загружены изображения с сервера SDSS по API в формате JPEG размером 128 на 128 пикселей, используя известные координаты. Каждому изображению была присвоена метка класса в соответствии с типом галактики. Примеры таких изображений представлены на рис. 1. Каждому изображению был присвоен тип галактики, в соответствии с исходными данными, отметка о морфологическом типе объекта была добавлена в конец имени соответствующего файла с изображением.




Рис. 1. Примеры загруженных изображений

Для повышения точности модели нами также произведена балансировка данных. Для построения сбалансированного классификатора были загружены изображения 10000 спиральных галактик, 10000 эллиптических галактик и 10000 неправильных галактик. Ниже будут приведены результаты классификации, полученные для сбалансированного и несбалансированного набора данных.

**Построение классификатора морфологических типов галактик.** Используя изображения, описанные выше, был разработан классификатор морфологических признаков галактик. Изображения для обучения нейронной сети были загружены с помощью функции `cv2.imread()` библиотеки OpenCV для чтения изображений из файлов, из имен файлов с изображениями были извлечены метки морфологических классов. Была построена свёрточная нейронная сеть с использованием библиотеки TensorFlow, включающая два слоя свертки и пулинга, слой Flatten для преобразования данных, а также два полносвязных слоя. Для повышения стабильности обучения был добавлен слой Batch Normalization. Данные были разделены на обучающий и тестовый наборы в соотношении 80% к 20%. Обучение проводилось в течение 20 эпох.

**Тестирование нейросетевых моделей классификатора.** Для несбалансированной выборки после обучения были получены следующие результаты классификации. Точность для правильно классифицированных изображений составила 67%. Для спиральных галактик (SPIRAL): точность – 72%, полнота – 77%, F1-мера – 75%. Для эллиптических галактик (ELLIPTICAL): точность – 60%, полнота – 58%, F1-мера – 59%. Для определения неправильных галактик (UNCERTAIN): точность – 48%, полнота – 31%, F1-мера – 37%.

Полученная модель классификатора также была протестирована на изображениях, полученных из астрономической базы данных HYPERLEDA [10]. Результаты классификации изображений представлены на рис. 2. Под буквой (А) приведены примеры эллиптических галактик, под буквой (Б) – спиральных галактик, под буквой (В) показаны примеры результатов распознавания неправильных галактик.

Модель показала довольно плохие результаты классификации для эллиптических галактик и средние результаты для спиральных и неправильных галактик. Для некоторых изображений присутствует низкая точность распознавания. Мы предположили высокую вероятность того, что полученные результаты

классификации связаны с дисбалансом в наборе данных, на котором производилось обучение модели.

Для проверки выдвинутой гипотезы нейросетевая модель описанной выше архитектуры была также обучена на сбалансированной выборке, в которой присутствовали изображения трех выделенных классов галактик в равных пропорциях.

При обучении и тестировании указанной модели были получены следующие результаты. Усредненная точность правильно классифицированных изображений увеличилась и составила 75%. Для спиральных галактик (SPIRAL): точность – 88%, полнота – 76%, F1-мера – 82%. Для эллиптических галактик (ELLIPTICAL): точность – 72%, полнота – 89%, F1-мера – 80%. Неправильные галактики (UNCERTAIN) показали следующие характеристики классификации: точность – 66%, полнота – 60%, F1-мера – 63%.




Рис. 2. Результаты классификации изображений галактик, полученных с сайта HyperLeda для модели, обученной на несбалансированных данных

Для модели нейросети, обученной на сбалансированной выборке галактик также было проведено тестирование на объектах, не входивших в изначальный набор данных. Изображения были выгружены из базы данных HYPERLEDA. На рис. 3 приведены примеры объектов, использованных для тестирования. Обозначения на рис. 3 соответствуют описанию рис. 2.






Рис. 3. Результаты классификации изображений галактик, полученных с сайта HyperLeda для модели, обученной на сбалансированных данных

Отметим, что для одних и тех же изображений новая модель показывает более точные результаты распознавания для каждого из выделенных классов объектов. Хотя для некоторых неправильных галактик точность классификации осталась низкой, пример такого объекта находится на второй позиции слева в нижнем ряду на рис. 3. Это может быть связано с тем, что такие объекты сильно отличаются друг от друга визуально и по этой причине проведенной балансировки обучающей выборки оказалось недостаточно для данного класса галактик.

**Заключение.** В результате проведенного исследования построена модель классификатора галактик по их морфологическим типам. Модель распознает три основных типа галактик, обучение нейросетевой модели производилось на двух наборах данных. Проведение балансировки выборки объектов различных типов показало увеличение точности определения класса галактики. Система показала адекватность своей работы для автоматизации классификации объектов в условиях постоянно растущего объема данных наблюдений.

Отметим, возникающие сбои при определении неправильных галактик. Для таких объектов модель показывает невысокие проценты правильного распознавания даже после проведения балансировки обучающей выборки. Эта проблема требует дальнейшего рассмотрения, в частности, планируются расширить выборку синтетическими данными.

Рассмотренный нами в этой работе метод построения морфологических классификатор будет расширен на анализ крупномасштабных галактических структур, таких как перемычки (бары) и различные особенности спиральной структуры дисковых галактик.

## Библиографический список

1. Gharat S., Dandawate Y. Galaxy classification: a deep learning approach for classifying Sloan Digital Sky Survey images // Monthly Notices of the Royal Astronomical Society. – 2022. – Feb. – Vol. 511, no. 4. – P. 5120–5124.
2. Morphological classification of Radio Galaxies using Semi-Supervised Group Equivariant CNNs / M. S. Hossain [et al.] // Procedia Computer Science. – 2023. – Vol. 222. – P. 601–612.
3. Reza M. Galaxy morphology classification using automated machine learning // Astronomy and Computing. – 2021. – Vol. 37. – P. 100492.
4. Practical galaxy morphology tools from deep supervised representation learning / M. Walmsley [et al.] // Monthly Notices of the Royal Astronomical Society. – 2022. – Feb. – Vol. 513, no. 2. – P. 1581–1599.
5. Fielding E., Nyirenda C. N., Vaccari M. A Comparison of Deep Learning Architectures for Optical Galaxy Morphology Classification // 2021 International Conference on Electrical, Computer and Energy Technologies (ICECET). – IEEE, 12/2021.
6. Martinazzo A., Espadoto M., Hirata N. S. T. Self-supervised Learning for Astronomical Image Classification. – 2020. – arXiv: 2004.11336
7. Galaxy Zoo: 3D – crowdsourced bar, spiral, and foreground star masks for MaNGA target galaxies / K. L. Masters [et al.] // Monthly Notices of the Royal Astronomical Society. – 2021. – Aug. – Vol. 507, no. 3. – P. 3923–3935.
8. GalaxyZoo – [Электронный ресурс]. Режим доступа: URL: <https://www.zooniverse.org/projects/zookeeper/galaxy-zoo/>
9. Sloan Digital Sky Survey – [Электронный ресурс]. Режим доступа: URL: <https://www.sdss.org/>
10. HyperLeda – [Электронный ресурс]. Режим доступа: URL: <http://atlas.obs-hp.fr/hyperleda>

## CLASSIFICATION OF GALAXIES BY MORPHOLOGICAL TYPES USING ARTIFICIAL NEURAL NETWORKS

*Panafidin Mikhail Nikolaevich, Butenko Maria Anatolievna*

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
[istb-211\\_496181@volsu.ru](mailto:istb-211_496181@volsu.ru), [maria\\_butenko@volsu.ru](mailto:maria_butenko@volsu.ru)

The paper presents a solution to the problem of automating the classification of galaxies by their morphological types using neural network technologies. A convolutional neural network model was designed using the TensorFlow library. Galaxy image data obtained by the SDSS project were used to train the model. The training sample was balanced for three selected classes of galaxies. Testing the model showed an increase in the average percentage of correctly recognized objects from 67% to 75% after balancing the data set. Note that the neural network model does a poor job of recognizing irregular galaxies. In general, the designed model adequately copes with its task and can be used for automated classification of observational data.

**Keywords:** neural network technologies, galaxy morphological type, classification problem, Sloan Digital Sky Survey (SDSS)



## Секция: Искусственный интеллект, педагогика и образование

УДК 004.89

### О ПРИЧИНАХ ПОСЛЕДСТВИЙ ПРИМЕНЕНИЯ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ШКОЛЕ

*Домбрин Игорь Михайлович*

Южный федеральный университет,  
347922, Россия, г. Таганрог, ул. Шевченко, 2  
dombrin@yandex.ru

В статье представлены возможные последствия применения технологий искусственного интеллекта в школе. Применение постнеклассической методологии для анализа проблемы позволяет выявить механизмы и причины влияния цифровых технологий на развитие личности.

**Ключевые слова:** искусственный интеллект в образовании, ИКТ в школе, цифровое образование, робот-учитель, последствия технологий.

**Введение.** В образовательную практику внедряются технологии ИИ. Демонстрируются выгоды от этого, но мало высвечиваются действительные угрозы развитию личности и общества. Применение интеллектуальных технологий вместо проявления собственных способностей приводит к деградации своих способностей, в том числе творческих. А способность творить необходима людям для решения личных жизненных и глобальных планетарных проблем.

Образование – это передача образов мира, культуры, и оно должно быть интегральным, целостным, что возможно только в непосредственном контакте «учитель-ученик». Интегральные образы необходимы для понимания основ мироздания. Понимание невозможно без баланса знаний и опыта, причём всех видов: от телесно-чувственного и эмоционального до интеллектуального и интуитивного. Отсутствие в образовательном процессе носителя живого опыта и непосредственного, а не дистанционного взаимодействия, лишает детей интегрального понимания мира. Если уровень массового образования будет падать, то и государство будет деградировать, потому что не будут рождаться лидеры и одаренные администраторы.

#### **Исследования последствий применения ИИ.**

Создание искусственного интеллекта влечет за собой немалое количество «вызовов» человечеству, его самоидентичности и перспектив дальнейшего развития [1, 5, 19, 20, 21, 22]. Исследования проблем применения ИИ начались ещё до создания ИИ. Писатели-фантасты (например, Станислав Лем) и ученые-кибернетики видели не только возможности, но и опасности от ИИ. Норберт Винер, один из создателей кибернетики, писал, что ни в коей мере не позволи-

тельно ставить на одну доску живые существа и машины. «Машины действуют по правилам, и правила эти, в корне отличные от норм доброжелательности, просты и безжалостны. Люди осуществляют свои желания с помощью процесса обратной связи. Если же этот механизм обратной связи встроен в машину, действие которой не может быть проконтролировано до тех пор, пока не достигнута конечная цель, вероятность катастрофы резко возрастает... Будущее оставляет мало надежд для тех, кто ожидает, что наши новые механические рабы создадут для нас мир, в котором мы будем освобождены от необходимости мыслить» [3].

Технологии позволяют человеку использовать внешние инструменты как продолжение самого себя. Это искусственные конечности, усилители ума, фантоматика. Человек перестает ощущать свое физическое тело, «непосредственные ощущения заменяются показаниями стрелок, мельканием лампочек и гудением приборов, которыми человек оснащается подобно тому, как автомобиль спидометром. Последний акт этой драмы – окончательное всеобщее истребление, которое заодно покончит и с жизнью вообще» [2].

В основном, угрозы и риски, связанные с развитием и массовым внедрением технологий ИИ, одинаковы для взрослых и детей. Однако для детей они усугубляются особенностями развития и восприятия окружающего мира [6]. Дети не в полной мере осознают опасность. Одна из угроз связана с использованием детьми генеративных моделей ИИ, которые не обеспечивают полноту и достоверность предоставляемой информации и могут способствовать приобретению детьми ложных или частично ложных сведений. К этому же риску присоединяется попадание в «информационный пузырь». Возрастает вероятность утечки личной информации. Никто не может гарантировать, что ИИ не будет применять эти личные данные при ответах на запросы других пользователей. Происходит привыкание детей к использованию ИИ-технологий в развлекательных или образовательных целях и возникновения цифровой зависимости, что может привести к отвлечению от реальной жизни и проблемам с социализацией. «Злоумышленники способны использовать ИИ-инструменты для кибербуллинга, отслеживания или манипуляций детьми» [8].

Приучение использовать искусственный интеллект вместо своего, естественного, ведёт к деградации [12]. Профессор лингвистики Наоми С. Бэрн полагает, что активное использование подобных технологий может негативно повлиять и на творческое, и на критическое мышление. По ее мнению, «соблазн положиться на инструменты редактирования и генерации текста... позволяет слишком легко отказаться от возможности думать и учиться в пользу технологий» [23].

Интеллектуальные образовательные платформы [4]:

- не могут обеспечивать такой же уровень социального взаимодействия, который можно найти в классных комнатах;
- не дают физического опыта. Наука, искусство и спорт, требуют практического опыта, который невозможно воссоздать на виртуальных платформах. Отсутствие прямого доступа к реальным лабораториям, студиям и спортивным объектам ограничивает опыт обучения в этих областях.

Цифровым обучением закрепляется так называемое «клиповое мышление» у ребенка. Одна из серьезных проблем даже не в том, что дети мало читают, а в том, что они не понимают смысла прочитанного, плохо понимают чужие мысли. «Тот, кто в юные годы много времени проводит за общением в Facebook, реже проявляет социальную активность в реальности. Это неизбежно приводит к социальной фрустрации, и именно поэтому виртуальное сообщество часто вызывает у подростков отрицательные эмоции», – пишет доктор Шпитцер [18]. Еще одна серьезнейшая проблема, связанная с цифровизацией – аутизм. Как заключает Кулебякина, «замещение цифровыми технологиями естественной передачи знаний от старшего поколения младшему неизбежно приведет к утрате навыков самостоятельного мышления» [7].

**Причины последствий применения ИИ.** Технологии искусственного интеллекта связаны с развитием пост-неклассической науки, поэтому, согласно теореме К. Геделя «О неполноте» [15], ответы на связанные с ее применением вопросы не могут быть логически обоснованы с использованием парадигм и средств более ранних стадий развития науки – классической и неклассической. Отсюда и «невидение» всех проблем со стороны разработчиков ИИ и экспертов, стоящих на классических позициях. Необходимо смотреть на проблему с вышестоящих позиций метасистемы. Современная пост-неклассическая интегральная антропология показывает более полную картину раскрытия такой сущности как человек. В человеке, согласно более адекватной физической действительности модели [11], мы видим процессы переработки и обмена веществом, энергией, информацией, пространства и времени (m, E, I, P, T). Школьник и учитель обмениваются не только информацией. Интегральная телесно-душевно-духовная модель проясняет, что кроме телесно-сенсорного, существует и душевно-энергетическое взаимодействие с окружающим миром. Интегральная теория показывает, что сознание личности – часть наиболее общего интегрального сознания [14]. Можно условно разделить сознание на четыре квадранта, каждый из которых в любом мгновении находится в человеке: объективно-индивидуальное (опыт, действия, поведение), объективно-коллективное (функциональные системы семьи, организации, общества), субъективно-индивидуальное (психологические качества личности) и субъективно-коллективное (принципы, ценности, культура). Все пространства сознания важны для взаимодействия и развития. Развитие происходит от уровня к уровню [9]. На интегральном уровне человек ценит все уровни бытия, реальности сознания и большой спектр человеческого опыта. Происходит поиск своего места в большем целом, будучи при этом отдельным существом, и сознательной подстройке к универсальному порядку. Осуществляется сбор и синтез различных систем ценностей в целостное и значимое целое. Интегральная школа – это интегральный учитель, интегральные ученики, интегральный класс. Это взаимодействие во всех пространствах и состояниях сознаниях, по всем линиям развития и в разных ролях. Развитие сочувствия и управления своим телом, воображение и эмоциональные переживания.

Непосредственное общение необходимо человеку всю жизнь. Известно, для развития речи у ребёнка, ему недостаточно слышать её, он должен видеть

мимику и артикуляцию матери. Никакие аудиоигрушки не научат ребёнка говорить, если он не видит лица разговаривающего человека. В нейропсихологии открыты возможности «зеркальных» нейронов, действующих на основе законов квантовой физики, нелокального взаимодействия. ««Зеркальные» нейроны передают навыки речи, мыслительных операций от взрослого человека ребёнку. Именно так: «зеркальные» нейроны взрослого передают информацию «зеркальным» нейронам ребёнка, которые, в свою очередь, запускают работу нужных зон коры мозга. Если информация будет подаваться ребёнку с другого источника, «зеркальные» нейроны не включатся. То же самое происходит во время учебного процесса: если при подаче учебного материала не участвовали «зеркальные» нейроны педагога, то не включатся мозги учеников» [7]

Искусственный интеллект – это модель интеллекта естественного, входящего в структуру человеческого сознания и служащего для обеспечения рационального мышления в системе языка. Метод ориентирующих обобщений показывает, что любые технические системы создаются для достижения одной из трех целей: 1) оказание человеку помощи в процессе выполнения им своих функций путем создания технических средств вспоможения и его органопроекции (микроскопы, телескопы, поисковые системы, подъемные устройства, средства передвижения...); 2) замещение отдельных функций человека средствами автоматизированных устройств и систем; 3) замещение человека, в целом, робототехническими системами [10].

К чему привели эти процессы в образовании? Они привели к замене непосредственного опыта взаимодействия «учитель-ученик», «мир-ученик» к использованию технических средств, лишаящих обучающихся именно интегрального опыта, а если последний отсутствует, понимание не может возникнуть. Цифровизация тех или иных аспектов образования унижает учеников до состояния объекта и товара [17]. В цифровых представлениях души и духа, сознания человека с его структурой и бесконечными возможностями уже не существует, поскольку их невозможно оцифровать. «Одна из целей робототехники – замещение человека в целом. И этот процесс также набрал огромную силу и скорость, иницируемый «благими намерениями», которыми, как известно вымощена дорога в ад. И этот ад будет концом этой человеческой цивилизации, что уже было на этой Земле, судя по культурным остаткам, и не один раз. Это один из способов сокращения населения Земли, потому что космосу биороботы не нужны. Космосу для сохранения и эволюции творческой иерархии нужны сотворцы, для чего человек на земле и создавался и воспитывался. Если существующая цивилизация этой надежды не оправдает, она также уйдет в небытие» [9, 10].

Только пользуясь моральной интуицией, слушая своё сердце, человек может принять решение. Основная моральная интуиция – это «защищать и поддерживать самую большую глубину для самого большого пространства» [14]. «В попытке поддерживать наибольшую глубину для наибольшего пространства мы должны научиться делать прагматические суждения о различиях во внутренней ценности, о степени глубины, которую мы разрушаем в попытке удовлетворить наши жизненные потребности». Конечно, у ИИ нет интуиции и

морали [13]. Изменив внешнюю ценность ИИ, перенеся свою задачу саморазвития на ИИ, получив своего интеллектуального слугу, человеку незачем развивать своё тело, ум, душу. А переложив ответственность, человек перестаёт быть тем, кем он является по предназначению – Творцом жизни [16].

**Заключение.** Пост-неклассическая методология показывает глубинные причины негативного влияния ИИ на учебный процесс. Что должно быть поводом для пересмотра отношений к ИИ со стороны разработчиков, законодателей и управленцев от образования. Разрабатывая и используя технологии, каждому человеку даётся шанс для выбора своей эволюции в течении жизни на планете Земля. Этот вызов – возможность для развития человека. Дж. Мур предлагал ограничить круг задач, решаемых компьютером таким образом, чтобы компьютер не мог решать, каковы должны быть базисные цели и ценности (и приоритеты среди них) человека, считая, в то же время этически неправомерным запрещение компьютеров там, где они могут способствовать сохранению человеческой жизни, например, в областях медицины.

Большинство детей сегодня не готовы работать с ИИ в соответствии со всеми требованиями информационно-психологической безопасности. Наряду с новыми возможностями высокие технологии таят и новые опасности, они значительно упрощают манипулирование сознанием, делают мнимой свободу человека в принятии тех или иных решений, приводят к утрате чувства реальности окружающего мира, способствуют индивидуализации общества и росту одиночества, создают угрозу существования человеческой телесности и подрывают представление о человеческой уникальности и неповторимости. Учителю же необходимо «жить» потребностями и интересами ребёнка, находиться рядом, чувствовать его (эмпатическое общение), что, конечно, невозможно сделать, перекладывая образование на системы ИИ.

### Библиографический список

1. Бостром Н. Искусственный интеллект. Этапы. Угрозы. Стратегии / Ник Бостром ; пер. с англ. С. Филина. – М. : Манн, Иванов и Фербер, 2016.
2. Вейценбаум Дж. Возможности вычислительных машин и человеческий разум. От суждений к вычислениям//Joseph Weizenbaum. Computer Power And Human Reason. From Judgment to Calculation The Massachusetts Institute of Technology (c) 1976 by W.H. Freeman and Company(c) Перевод на русский язык, предисловие и примечания, издательство "Радио и связь", 1982
3. Винер Н. Творец и робот: обсуждение некоторых проблем, в которых кибернетика сталкивается с религией //Изд-во Прогресс, М. – 1966, – 102с.
4. Дорошев Д.В. Искусственный интеллект в персонализированном обучении // "Мировая наука" №11(80) 2023, с.36-39
5. Дрейфус Х. Чего не могут вычислительные машины. Критика искусственного разума. М., 1978. С. 260
6. Коровникова Н.А. Искусственный интеллект в современном образовательном пространстве: проблемы и перспективы / Н.А. Коровникова // Социальные новации и социальные науки. – 2021. – № 2 (4). – С. 98-113.
7. Кулебякина Е. Риски цифровизации. – Режим доступа: <http://interunity.org/board/viewtopic.php?p=4938#4938>
8. Лаштун Е. Детки в ИИ-клетке. Что нужно знать родителям о влиянии искусственного интеллекта на детей // <https://rspectr.com/articles/detki-v-ii-kletke>

9. Непомнящий А. В., Домбрин И. М. Определить бытие или уйти в небытие: перспективы технокультуры // Современная наука: актуальные проблемы теории и практики. Серия: Познание. – 2018. -№10. – С. 34-40 <http://www.nauteh-journal.ru/files/b2e50026-bf6d-498e-b4a5-27a0a17a939d>
10. Непомнящий А.В., Нещадин И.О. Коллаборативная робототехника в образовании: цели и возможности. Мир университетской науки: культура, образование. 2023;(9): с.105-112. <https://woa.elpub.ru/jour/article/view/322>
11. Непомнящий А. В. Роль цифровых моделей жизненного контекста в процессе социализации личности. Научно-образовательный и прикладной журнал «Культура. Наука. Интеграция». – Ростов-на-Дону: Изд-во ЮФУ, 2017. – № 1(37). – С. 9–29.
12. Сафонов В.Н. Интеллектуальная деградация человечества – глобальная проблема // Вестник Ульяновского государственного технического университета. 2022. №4. – с.7-13
13. Синица А.С. Морально-этические аспекты теории искусственного интеллекта // «Молодой учёный» . № 18 (98) . Сентябрь, 2015 г., – с.419-422
14. Уилбер К. Краткая история всего// Кен Уилбер; пер. с англ. С. В. Зубкова – М.: АСТ, Астрель – 2006, – 476с.
15. Успенский В.А. Теорема Геделя о неполноте. М.: Наука. 1982. 112 с.
16. Успенский П.Д. Психология возможной эволюции человека; Космология возможной эволюции человека. СПб.: ИД «ВЕСЬ», 2001. 192 с.
17. Четверикова О.Н. Трансгуманизм в российском образовании. Наши дети как товар // Изво: Книжный мир, 2021 г. – 416с.
18. Шпитцер М. Антимозг. Цифровые технологии и мозг. М., Издательство АСТ, 2014 – Режим доступа: <https://www.litmir.me/br/?b=189102&p=1>
19. Юлковский Э. Искусственный интеллект как фактор глобального риска (отрывок, перевод А. Турчина, иллюстрации А. Костюкевича), журнал «Если 2015'3» 2015 г. (октябрь), стр. 236-247
20. Васильева: Цифровизация обучения приводит к атрофии мышления <https://www.nakanune.ru/news/2020/11/23/22588893/>
21. Известные ученые и инвесторы предупредили об угрозах искусственного интеллекта // URL: <http://www.vedomosti.ru/technology/articles/2015/01/13/ugrozy-iskusstvennogo-razuma> 13 января 2015
22. Илон Маск: Разработка ИИ сродни призыву демонов URL: <https://hi-ews.ru/technology/elon-mask-razrabotka-ii-srodni-prizyvu-demonov.html> 27 Октября 2014
23. Naomi S. Baron How ChatGPT robs students of motivation to write and think for themselves // <https://theconversation.com/how-chatgpt-robs-students-of-motivation-to-write-and-think-for-themselves-197875>

## ABOUT THE CAUSES OF THE CONSEQUENCES OF THE USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES IN SCHOOL

**Dombrin Igor**

Southern Federal University,  
2 Shevchenko str., Taganrog, 347922, Russia  
[dombrin@yandex.ru](mailto:dombrin@yandex.ru)

The article presents the possible consequences of the use of artificial intelligence technologies in school. The application of post-non-classical methodology to analyze the problem allows us to identify the mechanisms and causes of the influence of digital technologies on personal development.  
**Keywords:** artificial intelligence in education, ICT in school, digital education, robot teacher, consequences of technology.

## СОВРЕМЕННЫЕ ПРОБЛЕМЫ ВЫСШЕГО ОБРАЗОВАНИЯ РФ И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ

***Кузнецов Андрей Геннадьевич***

Пермский государственный гуманитарно-педагогический университет  
614068, г. Пермь, ул. Сибирская, 24

***Черепанов Федор Михайлович***

Пермский государственный гуманитарно-педагогический университет  
614068, г. Пермь, ул. Сибирская, 24

***Ясницкий Леонид Нахимович***

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
Национальный исследовательский университет  
«Высшая школа экономики»  
614070, Россия, г. Пермь, ул. Студенческая, 38  
yasn@psu.ru

Актуальная тема развития и внедрения в практику технологий искусственного интеллекта (ИИ) явственно обнаружила дефицит специалистов как со стороны разработчиков информационных систем с использованием технологий ИИ, так и собственно специалистов, способных развивать эти технологии. В настоящей работе рассмотрена тема подготовки кадров высшей квалификации как, в общем, в системе высшего образования РФ, так и применительно к подготовке специалистов для ИТ-отрасли. В работе приводятся конкретные примеры элементов образовательной программы в области искусственного интеллекта, основанных на многолетней практике внедрения технологий искусственного интеллекта в различных отраслях и опыта обучения многих поколений студентов. В частности, выделены основные факторы, обеспечивающие эффективность применения искусственного интеллекта при решении реальных задач науки, экономики и производства.

**Ключевые слова:** цифровая трансформация, развитие системы образования, технологии искусственного интеллекта.

**Введение.** Система высшего образования в Российской Федерации вошла в системный кризис, который формально был закреплен официальным отказом от болонской системы. В реальности кризис отражает разрыв между сложившейся в стране системой высшего образования и актуальными потребностями общества в результатах работы системы высшего образования. В тоже время, общество находится на этапе глобального цивилизационного вызова, обусловленного целым рядом кризисов (демографический, экологический, истощение природных ресурсов, климатический, ценностный и т.д.). А одним из очевидных выходов из сложившейся ситуации является переход к новому технологическому укладу, ключевым лозунгом которого является «Цифровая трансформация». Как и всякая глобальная компания, этот процесс сопровождается «хайпом» вокруг некоторых «модных» технологий. Несколько лет назад такой темой была технология блокчейнов или распределенных реестров. Сейчас это

технологии искусственного интеллекта. Но, как нам известно, «кадры решают все!»

И, следовательно, возрастает актуальность подготовки кадров в области компьютерных наук, информационных технологий и искусственного интеллекта, в частности.

**Блеск и нищета современного ИИ.** Возвращаясь к теме статьи, а конкретно к развитию технологий искусственного интеллекта и роли преподавания этой дисциплины, отметим, что цифровая трансформация производства, а в более широком смысле, промышленности и экономики, является актуальнейшим направлением развития научно-технического прогресса, основой нового технологического уклада. В числе наиболее перспективных технологий современного информационного общества – технологии искусственного интеллекта. Развитие технологий искусственного интеллекта (ИИ) обеспечило возможность создания систем автоматизации принципиально нового уровня, обеспечивающих высокий уровень эффективности производства и повышение качества продукции.

Используемые в настоящий момент автоматизированные системы управления опираются на логику и точные расчеты, применяя упрощенную «модель производственных процессов», выбранную заранее. ИИ позволяет создавать модели без введения упрощающих гипотез, учитывая неограниченное количество факторов, оказывающих влияние на производственный процесс и качество получаемых изделий. Кроме того, ИИ позволяет анализировать обстановку в реальном времени и сохранять работоспособность при смене целей управления, непредвиденных изменениях свойств управляемого объекта или параметров окружающей среды. Такая система способна менять алгоритм управления и искать оптимальные и эффективные решения. Можно забежать вперед и обозначить ИИ как область знания, занимающуюся автоматизацией разумного поведения технических и социальных систем.

Вместе с тем, как и любые технологии, технологии ИИ, наряду с очевидными достоинствами, объективно имеют недостатки, которые необходимо учитывать, принимая решение о применении решений, основанных на технологиях ИИ. И тем более необходимо минимизировать субъективные ошибки в организации процесса разработки и внедрения систем, основанных на технологиях ИИ.

Ученые механико-математического факультета Пермского классического университета (ПГНИУ) имеют многолетний опыт развития и применения методов искусственного интеллекта (ИИ) в самых различных предметных областях [1, 2], включая промышленность, экономику, социологию, политологию, медицину, психологию, педагогику, криминалистику, спорт и др. Обобщая этот опыт, в своем докладе на Восьмой всероссийской научно-практической конференции «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века» [3], мы сформулировали несколько правил, которые могут помочь избежать типичных ошибок, связанных с реализацией и внедрением технологий ИИ, и получить ожидаемый эффект. Приведем их здесь:



1. Не следует ждать чуда от ИИ. Методы машинного обучения действительно позволяют многое. Они способны извлекать знания из статистической информации и на их основе делать прогнозы, помогать принимать правильные решения. Но, если в предоставленных для обучения датасетах знаний нет, то методы машинного обучения бессильны.

2. Предприятия должны иметь возможность предоставить разработчикам ИИ достаточно полные датасеты, желательно, с минимумом ошибочной информации. На предприятиях должны быть определены сотрудники, заинтересованные в результатах проекта, способные собирать и предоставлять данные, активно участвовать в формулировке задачи и ходе выполнения проекта, иметь достаточную квалификацию для интерпретации промежуточных и финальных результатов.

3. Необходимо привлечение специалистов предприятия для подготовки необходимых датасетов с квалификацией, достаточной не только для формального переформатирования исходных данных, но и выявления недостоверной информации.

4. Успех машинного обучения напрямую зависит от объема обучающей выборки. Поэтому для применения методов машинного обучения хорошо подходят серийные предприятия, выпускающие существенные партии изделий, например, когда требуется снизить процент брака, улучшить качество продукции и др.

5. Методы машинного обучения позволяют создавать модели, учитывающие неограниченное количество факторов, влияющих на результат. Этим свойством полезно пользоваться, включая в датасеты сведения о как можно большем количестве параметров. Опыт показывает, что иногда факторы, казалось бы, не имеющие отношения к моделируемому явлению, оказываются важными для получения положительного результата.

6. Нейронные сети унаследовали от своего прототипа мозга множество положительных качеств. Но наряду с положительными, унаследовали и отрицательные. Например, способность обманывать человека, в частности, разработчика ИИ. Успешно пройдя все этапы тестирования, уже после передачи систем искусственного интеллекта заказчику, они могут выдать такой прогноз, который введет в ступор не только заказчика, но и разработчика. Поэтому руководителям предприятий не следует выбирать себе в исполнители недостаточно опытных разработчиков ИИ.

В последнее время, в связи необычайно возросшей популярностью ИИ, появилось много так называемых «продавцов ИИ». Как справедливо замечено в статье [3], «Освоив зарубежные программные инструменты на пользовательском уровне, очарованные рекламой, поверив в безграничные возможности ИИ, они смело берутся за выполнение грандиозных проектов. А руководители предприятий под воздействием все той же рекламы не скупятся на их финансирование. Участились случаи, когда такие проекты заканчиваются ничем, а иногда и требованиями вернуть аванс».

**Положительный опыт пермской научной и педагогической школы искусственного интеллекта.** Возникновению таких неприятных ситуаций во

многим способствует и несовершенство современных учебных программ преподавания ИИ. Отдавая должное глубокому освоению возможностей современных Python-библиотек, не следует забывать о необходимости изучения самих идей и принципов, заложенных в их основу. В качестве положительного примера, позволим себе рекомендовать учебники и методические пособия пермских ученых и преподавателей [4, 5, 6], в которых изучение материала ведется с соблюдением хронологической последовательности развития технологий ИИ так, что каждая новая идея, каждый новый метод появляются не случайно, а являются закономерным ответом на возникшие проблемы и парадоксы. В ходе более чем 30-ти летнего опыта преподавания этого курса в российских вузах, его удалось выстроить так, что несмотря на изначальную сложность, материал с легкостью усваивался студентами с совершенно разными уровнями подготовки. Изучение курса сопровождается выполнением лабораторных работ (скачиваются с сайта [www.LbAi.ru](http://www.LbAi.ru)), в основу которых заложена идея азартной компьютерной игры так, что их выполнение обходится практически без вмешательства преподавателя или лаборанта. Между учащимися и компьютерами завязывается активный диалог, в ходе которого учащиеся последовательно осваивают одну идею искусственного интеллекта за другой, иногда наталкиваясь на подводные камни и попадая в «ловушки», в которых порой оказывались ученые-создатели науки «Искусственный интеллект». Такой способ освоения материала, по нашему мнению, способствует глубокому проникновению в суть проблем, и не позволит в будущем повторять вошедшие в историю заблуждения и ошибки.

В ходе выполнения лабораторных работ, учащиеся осваивают специально созданный для них программный инструмент – «Нейросимулятор 5.0» (скачивается с сайта [www.LbAi.ru](http://www.LbAi.ru)). С помощью этого инструмента они создают структуры нейронных сетей персептронного типа, подбирают их параметры, оптимизируют, обучают решению конкретных практических задач. Некоторые задачи из области моделирования в промышленности, медицине, политологии, социологии, экономике, криминалистике, спорте и др. учащимся предлагается решить самостоятельно с помощью освоенного ими инструмента. Часто студенты придумывают темы сами, исходя из своих интересов и увлечений. Результаты успешно выполненных проектов ежегодно докладываются на ежегодной конференции, упомянутой выше. Так, в сборник материалов последней восьмой конференции 2022 года вошли научные статьи, написанные студентами по более чем 40 таким проектам. Бывали случаи, когда из таких экспериментальных студенческих работ вырастали вполне реальные инновационные проекты, ставшие основой для открытия новых успешных бизнесов, темой для защиты кандидатских и докторских диссертаций.

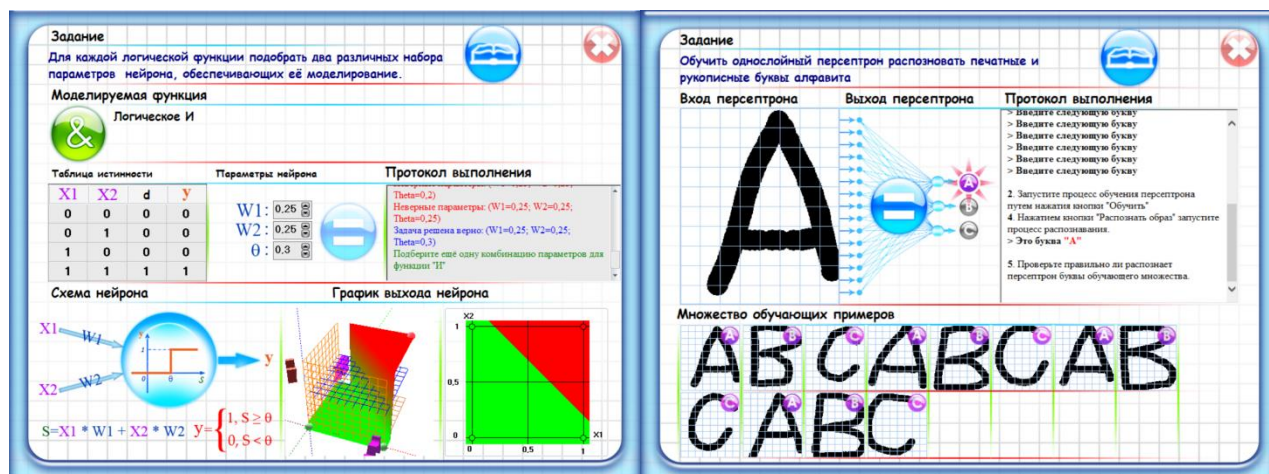


Рис. 1. Примеры графических иллюстраций к лабораторным работам

В настоящее время в Пермском крае сложилась уникальная ситуация, когда одновременно несколько коллективов ученых и разработчиков занимаются фундаментальными и прикладными исследованиями в области искусственного интеллекта применительно к различным областям науки и производства. Пермь заслуженно является одним из ведущих центров по разработке и внедрению систем ИИ. Примеры на слуху: это и всемирно раскрученный «Promobot», успешная реализация систем видеонаблюдения от компании «Macroscop», «ВИПАКС», «НЬЮВИЖИН-ЭМОЦИИ». Это интеллектуальные системы информационного противоборства от компании «СЕУСЛАБ», инженерные программные комплексы для оптимизации добычи нефти, разработанные компанией «НЕЙРОСОФТ ГЛОБАЛ», интеллектуальные системы прогнозирования и управления браком серийных промышленных предприятия, созданные компанией «Интеллект софт», и многие другие. Есть в этом заслуга и пермских преподавателей ИИ.

**Заключение.** Подводя итоги вышесказанного, отметим, что никакая, самая современная и остроумная технология не имеет шансов на успешное внедрение, если система образования не в состоянии обеспечить общество достаточным количеством квалифицированных специалистов. Никакая формальная система образования не способна выпускать необходимые обществу кадры, если основные стекхолдеры процесса (обучающиеся, работодатели, государственные институты образования и гражданское общество) не будут способны выработать консенсус по отношению к среднему и высшему профессиональному образованию.

### Библиографический список

1. Ясницкий Л.Н. Развитие научной школы искусственного интеллекта в пермских университетах: история и научный приоритет (обзорная статья) // Прикладная математика и вопросы управления. 2018. № 4. С. 99-130. <https://www.elibrary.ru/item.asp?id=36727550>
2. Ясницкий Л.Н. О научном приоритете пермских ученых в области искусственного интеллекта // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических

проблем XXI века. Часть I. Сборник статей по материалам Четвертой всероссийской научно-практической конференции, проводимой в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века». 2019. С. 7-25. <https://cloud.mail.ru/public/qzQE/3CTntPDdo>

3. Ясницкий Л.Н., Кузнецов А.Г. Как получить эффект от внедрения технологий искусственного интеллекта // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века : сборник статей по материалам Восьмой всероссийской научно-практической конференции с международным участием (г. Пермь, 25–26 октября 2022 г.) / под редакцией Л. Н. Ясницкого ; Пермский государственный национальный исследовательский университет. – Пермь, 2022. – С. 9-11. [https://www.permai.ru/files/sbornik\\_trudov\\_10\\_2022.pdf](https://www.permai.ru/files/sbornik_trudov_10_2022.pdf)

4. Ясницкий Л.Н. Интеллектуальные системы : учебник. М.: Лаборатория знаний, 2016. 221 с. (Рекомендовано УМО по классическому университетскому образованию в качестве учебника для студентов вузов направления «Фундаментальная информатика и информационные технологии»). <https://cloud.mail.ru/public/5H3z/4LxCpisxw>

5. Ясницкий Л.Н. Искусственный интеллект. Элективный курс: Учебное пособие. – М.: БИНОМ. Лаборатория знаний, 2011. – 240с. (Свободно скачивается с сайта [www.LbAi.ru](http://www.LbAi.ru))

6. Ясницкий Л.Н., Черепанов Ф.М. Искусственный интеллект. Элективный курс: Методическое пособие по преподаванию. – М.: БИНОМ. Лаборатория знаний, 2012. – 216с. (Свободно скачивается с сайта [www.LbAi.ru](http://www.LbAi.ru))

## CONTEMPORARY PROBLEMS OF HIGHER EDUCATION IN THE RUSSIAN FEDERATION AND ARTIFICIAL INTELLIGENCE

***Andrey G. Kuznetsov***

Perm State Humanitarian-Pedagogical University  
614068, Perm, Sibirskaya St., 24

***Fedor M. Cherepanov***

Perm State Humanitarian-Pedagogical University  
614068, Perm, Sibirskaya St., 24

***Leonid N. Yasnitsky***

Perm State National Research University,  
614068, Russia, Perm, Bukireva St., 15  
National Research University  
Higher School of Economics  
614070, Russia, Perm, Studencheskaya, 38  
[yasn@psu.ru](mailto:yasn@psu.ru)

The current topic of development and implementation of artificial intelligence (AI) technologies has clearly revealed a shortage of specialists both on the part of developers of information systems using AI technologies and specialists capable of developing these technologies. This paper examines the topic of training highly qualified personnel both in the higher education system of the Russian Federation in general and in relation to the training of specialists for the IT industry. The paper provides specific examples of elements of the educational program in the field of artificial intelligence, based on many years of practice in implementing artificial intelligence technologies in various industries and the experience of teaching many generations of students. In particular, the main factors that ensure the effectiveness of using artificial intelligence in solving real problems of science, economics and production are highlighted.

**Keywords:** digital transformation, development of the education system, artificial intelligence technologies.

## ФОРМИРОВАНИЕ ДИНАМИЧЕСКОГО РЕЙТИНГА УЧАЩИХСЯ В ОБРАЗОВАТЕЛЬНОМ ПРОЦЕССЕ

*Горелик Самуил Лейбович*

Институт интеграции и профессиональной адаптации (Израиль), Университет ИТМО  
samgor46@gmail.com

*Грудинин Владимир Алексеевич*

Университет ИТМО  
grudinin@itmo.ru

В статье представлено описание технологии формирования динамического рейтинга учащегося с использованием методов кросс-тестирования.

**Ключевые слова:** кросс-тестирование, рейтинг учащихся, образовательные технологии.

**Введение.** В современной системе образования прочно устоялась система обучения с помощью типовых задач и тестов, которая, к сожалению, плохо стимулирует самостоятельное осмысление вопроса учащимися, не стимулируют навыки структурирования информации, построения информационных связей, способности выделять главное и второстепенное

Важнейший вопрос, который стоит перед современной системой образования – проблема сознательного усвоения знаний, в основе которого лежит умения осмыслять и критически оценивать материал, которое невозможно проверить с помощью шаблонного группового тестирования.

Предлагаемая нами система кросс-тестирования основана на материалах исследований [1,2] может стать системным мета предметным инструментом, который позволит существенно продвинуться в этом направлении

Система базируется на уникальной цифровой образовательной платформе индивидуально-группового обучения, объединяющей в себе доступ к теоретическому материалу с проверочными вопросами, инструмент для создания тестов и математические алгоритмы случайного распределения задач и метода дифференцированного оценивания. В основе системы дидактические приемы – тестирование по системе multiple choice и самостоятельное составления вопросов и задач. Оба эти приема используется в разном объеме и вариантах в системе традиционного обучения и знакомы ученикам и преподавателям. Система кросс-тестирования объединяет эти приемы в единый комплекс и совмещает с современными цифровыми технологиями, что позволяет каждому ученику глубже и прочнее усвоить полученные знания по теме, проявить индивидуальные способности, а также развить критическое мышление Важной особенностью предлагаемой системы является включение специального бота, основанного на принципах ИИ с обучением в процессе тестирования в состав тестируемой группы анонимно. Такое решение позволяет объективно сравнивать индивидуальные и групповые показатели различных групп учащихся.

Алгоритм работы системы состоит из пяти этапов.

1) Первый этап включает в себя:

а) установочный модуль, который может быть представлен в традиционной форме урока (лекции) или изложение теории в цифровом виде в программе QWiz (или совмещение обоих вариантов), при необходимости дополненные ссылками на дополнительные источники;

б) контрольные установочные вопросы (тест) от преподавателя, для оценки текущего состояния знаний учащегося и служащих образцами вопросов по данной теме.

Теоретический материал прорабатывается каждым учеником в группе или индивидуально, ответы на установочные вопросы теста от преподавателя поступают в систему QWiz.

2) На втором этапе учащимся необходимо самостоятельно составить задачи (или вопросы) для других учеников по пройденной теме, подобрать возможные ответы и подробно объяснить свой вариант решения (с указанием ссылки на теоретический материал, объясняющий правильность представленного варианта решения, если это необходимо). Все самостоятельно составленные задачи поступают в систему QWiz без предварительного мониторинга преподавателем.

3) На третьем этапе учащиеся получают задачи, составленные их коллегами по обучению, проводят их анализ и выбирают правильные, на их взгляд, варианты ответов, получая обратную связь от системы (верность-неверность ответа и правильный вариант решения). Ответы учащихся поступают в систему QWiz.

4) Задача четвертого этапа – программная дифференцированная оценка результатов, включающих в себя оценку правильности ответов на контрольные вопросы от преподавателей и других учеников, и оценку за самостоятельное составление задач (критерии оценки будут рассмотрены ниже).

5) На заключительном этапе подсчитываются баллы по комплексу заданий по данной теме и формируются рейтинги учащихся, показывающие не только не только уровень и качество приобретенных навыков и знаний, но и динамику их изменения во времени, дают возможность не только сравнивать разных учащихся (соревновательный элемент).

**Применяемые технологии и алгоритмы.** Основа системы кросс-тестирования является самостоятельное составление учащимися задач, которые должны решить другие учащиеся. Для начала нужно определить, «постановка вопроса» предполагают связь между тем, что спрашивается (предикат вопроса), и теми знаниями, которыми располагает спрашивающий (они заложены в самом вопросе), а также связь вопроса с возникновением проблемной ситуации и ее творческого переживания.

Вопросы, задаваемые самими учениками, задействуют важнейшие функции, которые являются залогом успешного процесса обучения.

Решение задач – метод, совмещения процессов конкретизации и обобщения. Процесс решения конкретных задач – это продолжение и углубление усвоения теоретического материала и наполнение теории в сознании учащихся конкретным содержанием, раскрывающим жизненное значение понятий, формул или правил. Но, решая задачи или отвечая на вопросы, составленные авторами учебника или рабочей тетради, учащиеся не всегда глубоко проникают в суть

этой взаимосвязи, так как примеры и явления, иллюстрирующие теоретический материал не всегда им близки или даже понятны. В процессе самостоятельного составления задачи и подбора материала эта связь выявляется и закрепляется самим учениками на тех примерах, которые наполнены смыслом именно для них. Благодаря этому, знания актуализируются, наполняются личностной значимостью, приобретают более глубокий смысл и системность. [4]

На этапе формулирования вопроса результаты мыслительной деятельности фиксируются в словесном, математическом, буквенном, графическом и т.д. выражении, в тексте вопроса/ задачи или при составлении примера/формулы, тем самым развивая логическое мышление, коммуникативные навыки и культуру речи.

Другим важным элементов заданий данного типа (составления задачи и вариантов ответа по типу multiple choice) является необходимость подбора нескольких возможных вариантов ответа (одного правильного и заведомо неверных). Правильный ответ должен быть подтвержден и проиллюстрирован теоретическим материалом, примером или вариантом решения. Если работа идет с несколькими источниками, то должны быть даны соответствующие ссылки для подтверждения правильности ответа.

Особая роль отводится подбору вариантов неправильных ответов. Для успешного выполнения этой части задания, ученику нужно продумать возможные типичные ошибки и подобрать те варианты ответов, которые могут быть получены при неверном решении. Таким образом, составление одной задачи или вопроса- это процесс, который требует вдумчивой работы с теоретическим материалом для выявления проблемы, обдумывания формулировки вопроса, творческой работы для подбора релевантных данных и глубокого анализа для определения возможных вариантов ответа.

**Система оценки.** Необходимым условием для выполнения всех этих шагов является мотивация учащихся к созданию не шаблонных задач по образцу, а оригинальных задач с достаточно высоким уровнем сложности. Как этого добиться? Ведущая роль отводится дифференцированной системе оценки и соревновательному компоненту системы.

Алгоритм системы кросс-тестирования распределяет задачи в случайном порядке, что сводит к минимуму возможность списать правильный ответ таким образом, что одна и та же задача попадает к нескольким ученикам. В зависимости от процента правильных ответов, задача классифицируется как «простая» (81-100% правильных ответов) с присвоением минимального количества баллов или «решаемая» (30-80% правильных ответов) с присвоением повышенного количества баллов в системе. Важно обратить внимание ученика, что предложенные варианты неправильных ответов, могут как усложнить, так и упростить решение (например, возможность выбрать верный ответ методом исключения) и поэтому, их подбор требует вдумчивого отношения. Отдельно обговариваются ситуации, когда задача имеет, несколько возможных вариантов решения.

Если количество правильных ответов составляет менее 30 процентов, существует вероятность, что задача/варианты ответов составлены неверно или задача относится к категории повышенной сложности. В этом случае, система присваивает данной задаче «тревожный приоритет» и направляет на рассмот-

рение преподавателю, который признает ее либо «ошибочной», либо «сложной», с соответствующим выставлением баллов.

В зависимости от целей, которые ставит преподаватель, «сложные» задачи могут оцениваться выше «решаемых» или нет. Правильно составленная задача с верно подобранными вариантами ответа и четкой аргументацией правильного решения – оптимальна соответствует задаче группового обучения в системе.

«Тревожный приоритет» может быть также выставлен самим учеником на всех этапах решения задач (как преподавателя, так и других учеников), в случаях неправильной (по мнению ученика) формулировки задачи, несогласия с решением, представленным автором, отсутствия логики, перегруженности/недостатком информации и т.д. Выставление «тревожного приоритета» должно быть объяснено и/или подкреплено отличным от авторского вариантом решения и ответа. Задачи с «тревожным приоритетом» от учеников, поступают на арбитраж преподавателю, который либо начисляет повышенное количество баллов за «критичность», либо снимает баллы за «необоснованность претензий».

Таким образом, ученики не только выступают в роли учителей друг для друга, что в большинстве случаев уже является мощным мотивационным стимулом для создания нестандартных задач, но приходят к пониманию, что для получения максимального количества баллов важно выбрать правильную тактику при составлении задачи, учитывая все возможные сценарии оценки.

Анализ ошибок в самостоятельно составленных задачах помогает выявить индивидуальные пробелы в знаниях каждого ученика и определить, что именно вызывает затруднение (непонимание теории, отсутствие логических связей, ошибки в расчетах, невнимательность и т.д.)

В результате автоматизированной обработки данных преподаватель и ученик могут объективно оценить результат усвоения конкретной темы, наличие навыков использования знаний, и уровень креативных и аналитических способностей. Располагая этими данными, преподаватель сможет выработать индивидуальные рекомендации, что практически невозможно при традиционном подходе.

Система формирует рейтинги учащихся, которые показывают не только уровень и качество приобретенных навыков и знаний, но и динамику их изменения во времени, дают возможность сравнивать результаты разных учащихся или группы учащихся (личные и командные соревнования) и отражают динамику процесса обучения. Рейтинги формируются на основе принципов робастной статистики и являются устойчивыми в математическом смысле оценками исследуемых процессов. Прогресс или регресс в процессе обучения каждого ученика определяется на основе оценки статистически значимых увеличений или уменьшений рейтингов за период мониторинга.

Учитывая тот факт, что новая программа развития образования нацелена на цифровую трансформацию, система кросс-тестирования может быть использована на всех этапах обучения, начиная с начальной школы, заканчивая высшим и профессиональным образованием.

### **Выводы.**

1. Использование цифрового инструмента обучения поколения 4.0, сочетающего в себе индивидуальный и групповой формат выполнения заданий с



персонифицированным подходом к оценке знаний и анализом ошибок, позволит каждому ученику лучше усвоить знания и развить навыки, необходимые в современном мире.

2. Разработанная система в течение нескольких лет в специальном курсе «Мобильные технологии в системах государственного управления» (Университет ИТМО для магистрантов. Настоящее время начинается внедрение в регулярную учебную программу одного из факультетов.

3. Мы приглашаем к сотрудничеству другие учебные заведения.

### **Библиографический список**

1. Управление в образовательных системах, АСЫКО Т.Н., ГОРЕЛИК С.Л., ЧЕРНЫШКОВА М.А., Санкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики, Сборник трудов конференции «ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ В УПРАВЛЕНИИ» (ИТУ-2014), Страницы: 826-829

2. Образование в цифровую эпоху. С.Л.Горелик. Электронный научно-технический журнал «Magellan» 2019 г. вып.1.  
<https://magellan.pro/2019/03/04/obrazovanie-v-cifrovuyu-jepohu/>. Дата последнего обращения: 23 октября 2019 г.

3. Обучение самостоятельной постановке проблемных вопросов и составлению задач как условие развития творческих возможностей учащихся. Диссертация кандидата педагогических наук / Т.В. Певчева : Москва, 1994. – 243 с. <https://search.rsl.ru/ru/record/01000179037> . Дата последнего обращения: 23 августа 2024 г.

4. Самостоятельное составление учащимися задач как средство повышения сознательности знаний: Автореферат диссертации. на соискание ученой степени кандидата педагогических наук / Ю. И. Хайдуков ; Ленингр. гос. пед. ин-т им. А. И. Герцена. – Ленинград, 1951.- 13 с. [http://www.mathedu.ru/lib/aref/haydukov\\_yu\\_i\\_1951/](http://www.mathedu.ru/lib/aref/haydukov_yu_i_1951/) Дата последнего обращения: 23 сентября 2024 г.

### **FORMATION OF DYNAMIC RATING OF STUDENTS IN THE EDUCATIONAL PROCESS**

***Gorelik Samuil Leibovich***

NIIapa (Israel), ITMO University (SPb)  
[samgor46@gmail.com](mailto:samgor46@gmail.com)

***Grudin Vladimir Alekseevich***

ITMO University (SPb)  
[grudin@itmo.ru](mailto:grudin@itmo.ru)

A human being, as an individual object, is the most important part of a social ecosystem (which in turn consists of communities) and is itself a biological ecosystem managed based on the general laws of nature. A mathematical model of a human being includes its biological and social characteristics. For example, factors that determine its knowledge and skills in the process of continuous education, as well as other factors that affect performance, related to health and other tangible and intangible assets. The results of research and development of a methodology and software and technology solutions for forming a digital image in the process of continuous learning throughout the entire life cycle are the subject of this work.

**Key words:** cross-testing, student rating, educational technologies.

## **ИСПОЛЬЗОВАНИЕ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В РЕШЕНИИ ОБРАЗОВАТЕЛЬНЫХ И ПРИКЛАДНЫХ ЗАДАЧ: ЭКСПЕРИМЕНТАЛЬНЫЙ ПОДХОД**

***Рыжкова Марина Вячеславовна, Былкова Татьяна Васильевна,  
Непомнящая Юлия Александровна,  
Беляк Данил Кириллович***

Национальный исследовательский Томский государственный университет,  
634050, Россия, г. Томск, пр. Ленина, 36  
Национальный исследовательский Томский политехнический университет,  
634050, Россия, г. Томск, пр. Ленина, 30  
marybox@inbox.ru, ftv8282@mail.ru

Исследование нацелено на оценку результативности применения ИИ в образовательном процессе и при решении кейсов. В качестве метода оценки был использован образовательный эксперимент со студентами вуза, которые использовали чат-боты для подготовки ответов на поставленную учебную задачу. Было проверено три гипотезы: 1. Могут ли студенты познавать с помощью чат-бота? 2. Могут ли студенты заменить поисковик чат-ботом? 3. Могут ли студенты найти информацию под конкретную задачу, используя только чат-бот? Полученные результаты помогли развеять ряд опасений, связанных с негативным влиянием генеративного искусственного интеллекта на образовательную среду.

**Ключевые слова:** образовательный эксперимент, нейросети, чат-бот, обучение студентов

**Введение.** Чуть больше года прошло с момента появления ChatGPT – первого чат-бота с генеративным искусственным интеллектом (ИИ) в основе, способного вести диалог на естественном языке. Многие формы образовательных заданий после этого потеряли актуальность. В настоящее время не ясна степень и глубина образовательных трансформаций, которые вследствие этого могут произойти. Если невозможно отменить инновацию, то нужно ее включить в образовательный процесс. В своем исследовании мы разработали вариант такой практики. Она позволит определить потенциальные эффекты использования генеративного ИИ.

Сейчас в педагогическом сообществе сложилось два подхода к использованию ИИ: отрицание (запрет) и попытка принятия (изменение методик). Система «Антиплагиат» дополнена модулем выявления сгенерированного текста. Напрямую выдавать сгенерированный текст за свой нельзя. Перед преподавателями стоит задача, как сделать нейросеть удобным инструментом получения новых знаний [1]. Опасность пользования нейросетями заключается в безусловном доверии студента результатам поиска: в модели отсутствует система логического вывода, поэтому она может ошибаться в рассуждениях, и делать неверные выводы, хотя текст выглядит согласованным и убедительным [2]. Результаты, полученные коллегами ранее [3], позволяют разработать критерии

для измерения потенциальных эффектов использования генеративного искусственного интеллекта.

Целью представленного исследования мы видим определение путей и результативности использования студентами разной степени осведомленности генеративного ИИ для выполнения учебных задач.

Гипотеза: использование чат-бота позволит студентам подготовить конкретный ответ на поставленную учебную задачу.

**Методология исследования.** Для достижения цели и проверки гипотезы нами был спланирован и проведен образовательный эксперимент [4]. Перед тремя группами студентов были поставлены три разные задания, предполагающие последовательность запросов у чат-ботов на выбор студента из предложенного списка. По окончании процесса поиска производилась самооценка результативности и оценка результата преподавателем.

Эксперимент состоял из трех частей.

Часть 1. «Новички готовятся к экзамену с помощью чат-бота».

Выборка. 97 студентов НИ ТГУ 1-го курса (направление Экономика). Студенты без предварительной подготовки формулировали «промт» бесплатным чат-ботам (без vpn) для подготовки ответа на экзамен по 1-му слайду презентации. Проверялось, подходит ли этот инструмент для самостоятельной проработки лекционного материала, и может ли студент формулировать задачу по незнакомому материалу. В выборке было крайне мало студентов, которые пользовались чат-ботами до этого.

Задание. Студенты заранее получили презентацию лекции по дисциплине «Микроэкономика» по теме «Олигополия. Монополистическая конкуренция». На самой лекции мы предложили три чат-бота («Perplexity», «You.com», «Monica») и план работы (9 пунктов). Студенты фиксировали ответы в электронном курсе на базе LMS Moodle.

Часть 2. «Чат-бот против поисковика»

Выборка. 19 студентов НИ ТПУ 3-го курса (направление Экономика). Студенты без предварительной подготовки использовали бесплатные чат-боты (без vpn) по предложенному списку или привычные для них. В выборке были люди, которые уже пользовались чат-ботами на регулярной основе для разных задач.

Задание. Студентам раздали названия разнообразных компании г. Томска и нужно было разработать «легенду» для задания: принять на работу сотрудника, расписать критерии, особенности и другие ситуации, произвести поиск сотрудника. Студенты описывали деятельность компании, придумывали легенду по искомой вакансии и имеющейся проблемы и составляли подробный отчет о своем пути поиска и его результативности. Из двух студентов в паре один искал информацию с помощью чат-бота, другой с помощью поисковой системы. В конце производилось коллективное обсуждение результатов поиска.

Часть 3. «Чат-бот в руках мастера».

Выборка. 2 студента, подрабатывающих на вакансиях, требующих использование чат-ботов. Чат-боты использовались современных версий с платным доступом.

Задание. Совпадает с заданием второй части. Их целью является получение результата, аналогичного результату второй части. Производится сравнение результатов 2 и 3 этапов с целью выявления зависимости результата от квалификации пользователя и качества чат-бота.

**Результаты образовательного эксперимента.** В процессе выполнения заданий студентами выявлено, что чат-боты ошибаются в рассуждениях, несмотря на то, что сгенерированный текст выглядит на первый взгляд согласованным и убедительным.

2. Подготовка студента перед выполнением задания, его общая эрудированность и знания по теме – важный фактор корректности составления «промпта» и оценки сгенерированного им результата.

3. Пользование чат-ботом требует от студента владения основами методологии научного познания: формулировки цели и задач поиска, декомпозиции задачи, понимания структуры предметной области поиска.

В целом, три части проведенного образовательного эксперимента показали. Во-первых, опасения, что чат-бот заменит думающего студента, беспочвенные. Во-вторых, проведенная эмпирическая проверка указывает, что решение учебной слабоструктурированной задачи с помощью чат-бота не дает конкретный, гарантированно правильный результат. Требуется его верификация с помощью традиционных методов поиска. В-третьих, использовать чат-бот для решения практической задачи возможно, но как дополнительный инструмент при формировании алгоритма и его реализации на отдельных этапах. Для учебной задачи вполне подходит, для организации проверки образовательного результата.

**Заключение.** Важно отметить новизну проведенного исследования. Во-первых, многие исследования отражают результаты испытаний чат-ботов как инструмента преподавателя. Наш фокус на исследовании чат-ботов как инструмента студента для организации процесса познания и решения конкретной учебной задачи. Мы задействовали разные уровни владения нейросетями (от студентов-неофитов до профи).

Во-вторых, включенное наблюдение позволило нам избежать результата, основанного на опросе студентов. Он ограничивает результат, который основан только на единичном наблюдении, описанного в публицистической литературе («vc.ru», «dzen» и др.),

**Благодарности.** Авторы выражают признательность студентам Томского государственного университета (ТГУ) и Томского политехнического университета (ТПУ) за работу в нейросетях.

### Библиографический список

1. Корякова, К. А. Нейросети как новые инструменты в образовании / К. А. Корякова, О. В. Судакова // Информационные технологии в образовании. – 2023. – № 6. – С. 180-186. – EDN CZWHJQ.
2. Карлов И.А. Генеративный искусственный интеллект в образовании / Карлов И.А. [Электронный ресурс] // ioe.hse.ru : [сайт]. – URL: [https://ioe.hse.ru/data/2023/03/29/2022591510/ChatGPT\\_Karlov.pdf](https://ioe.hse.ru/data/2023/03/29/2022591510/ChatGPT_Karlov.pdf) (дата обращения: 10.09.2024).

3. Константинова Л. В., Ворожихин В. В., Петров А. М., Титова Е. С., Штыхно Д. А. Генеративный искусственный интеллект в образовании: дискуссии и прогнозы // Открытое образование. 2023. №2. URL: <https://cyberleninka.ru/article/n/generativnyy-iskusstvennyy-intellekt-v-obrazovanii-diskussii-i-prognozy> (дата обращения: 10.09.2024).
4. Соснин Э.А., Пойзнер Б.Н. Методология эксперимента: учебное пособие. М.: «Информ–М», 2017 162 с.

## **THE USE OF GENERATIVE ARTIFICIAL INTELLIGENCE IN SOLVING EDUCATIONAL AND APPLIED PROBLEMS: AN EXPERIMENTAL APPROACH**

***Ryzhkova Marina Vyacheslavovna, Bylkova Tatyana Vasilyevna,  
Nepomnyashchaya Yulia Alexandrovna, Belyak Danil Kirillovich***

National Research Tomsk State University,  
634050, Russia, Tomsk, Prospect Lenina, 36  
National Research Tomsk Polytechnic University,  
634050, Russia, Tomsk, Prospect Lenina, 30  
[ftv8282@mail.ru](mailto:ftv8282@mail.ru)

The study aims to evaluate the effectiveness of using AI in the educational process and in solving cases. An educational experiment with university students who used chatbots to prepare answers to a set educational task was used as an evaluation method. Three hypotheses were tested: 1. Is it possible for students to learn using a chat-bot? 2. Can students replace a search engine with a chat-bot? 3. Can students find information for a specific task using only a chatbot? The results obtained helped to dispel a number of concerns associated with the negative impact of generative artificial intelligence on the educational environment.

**Keywords:** educational experiment, neural networks, chat-bot, student learning

УДК 004.93'12

## **НЕЙРОСЕТЕВОЕ РАСПОЗНАВАНИЕ ЛИЦ В ВИДЕОПОТОКЕ СИСТЕМЫ АВТОМАТИЧЕСКОГО КОНТРОЛЯ ПРИСУТСТВИЯ СТУДЕНТОВ НА ЗАНЯТИИ**

***Федяев Олег Иванович***

ФГБОУ ВО «Донецкий национальный технический университет»,  
283001, Россия, ДНР, г. Донецк, ул. Артёма, 58  
[olegfedyayev@mail.ru](mailto:olegfedyayev@mail.ru)

***Суханов Антон Алексеевич***

ФГБОУ ВО «Донецкий национальный технический университет»,  
283001, Россия, ДНР, г. Донецк, ул. Артёма, 58  
[studysukhanov@mail.ru](mailto:studysukhanov@mail.ru)

Рассматривается задача видеорегистрации присутствия студентов на учебном занятии. Распознавание лиц студентов осуществляется в режиме реального времени с помощью свёрточной нейронной сети модели VGGFace. Система видеоконтроля фиксирует лица студентов на

видеокамеру при входе в комнату, сравнивает лица с базой данных студентов, отмечает присутствие на лекции (или опоздание) и в случае успешной идентификации сохраняет данные в электронном журнале. При проведении лекций с большим количеством студентов данная система позволит автоматизировать учёт присутствия студентов в учебных классах и накапливать статистические данные об учебной дисциплине каждого студента в течение семестра.

**Ключевые слова:** компьютерное зрение, свёрточная нейронная сеть, распознавание лиц, видеопоток, регистрация студентов в аудитории.

**Введение.** В статье приводится постановка и решение конкретной задачи оперативного визуального контроля присутствия студентов на учебных занятиях с помощью компьютерного зрения. Актуальность данной задачи обусловлена, во-первых, потерями времени преподавателя, которые возникают при ручной регистрации присутствия большого количества учащихся в аудитории (в потоке из 70 человек потери на «переключку» составляют в среднем 85 мин в семестре и даже больше); во-вторых, «переключка» проходит шумно и не всегда достоверно.

Основные трудности компьютерного распознавания лиц в реальном времени связаны с быстрой изменчивостью изображений объектов в видеопотоке: положение, размер и ракурс лица в кадре, освещение и т. д. [1]. В настоящее время большие перспективы в преодолении перечисленных проблем связывают с применением глубоких нейронных сетей. К этому классу относится многослойная свёрточная нейронная сеть (Convolutional Neural Network) [1, 2], которая является развитием идей таких архитектур нейронных сетей, как многослойные сети типа когнитрон и неокогнитрон [3].

На данный момент свёрточная нейронная сеть и её модификации считаются лучшими по точности и скорости распознавания объектов на изображении. Более того, распознавание лиц из видеопотока с камеры показывает, что нейронные сети с такой архитектурой способны работать в режиме реального времени даже на устройствах с ограниченными ресурсами.

В последнее время известными фирмами предложены мощные библиотеки, в которых реализованы различные модели глубоких нейронных сетей, позволяющие решать сложные задачи распознавания. Поэтому целью данной работы является оценка возможности реализации нейросетевого распознавания лиц из видеопотока на базе существующих инструментальных средств [4, 5] и создание системы оперативного визуального контроля присутствия студентов на учебных занятиях.

**Постановка задачи компьютерного распознавания лиц.** Введём следующие обозначения:  $L$  – множество фамилий распознаваемых людей по лицам (например, список студентов в группе);  $\bar{X}$  – множество подготовленных фотографий распознаваемых лиц, т.е. эталоны изображений распознаваемых лиц;  $l$  – фамилия человека ( $l \in L$ ), фотография которого изображена на снимке  $\bar{x}$  ( $\bar{x} \in \bar{X}$ ).

Предположим, что есть функция  $f$ , которая способна выявлять признаки лица по его изображению. С её помощью можно сформировать множество  $\bar{Y}$  из векторов признаков, выявленных на фотографиях  $\bar{X}$ :

$$f: \bar{X} \rightarrow \bar{Y}.$$

Тогда элемент этого множества  $\bar{y}$  – это вектор признаков одной из фотографий  $\bar{x}$  лица человека с фамилией  $l$  ( $l \in L$ ). В результате получаем базу данных для распознавания людей по лицам в виде множества  $V$ :

$$V = \{(\bar{y}, l) \mid \bar{y} = f(\bar{x}), \bar{x} \in \bar{X}, l \in L\}.$$

Соотношения между мощностями множеств можно представить в виде следующих неравенств:

$$|\bar{X}| \geq |L|, |\bar{X}| = |\bar{Y}|.$$

Система компьютерного зрения в режиме распознавания человека по изображению его лица  $x$  должна, во-первых, применить к  $x$  свой функционал  $f$  для формирования вектора признаков  $y$  ( $f: x \rightarrow y$ ) и, во-вторых, для него найти в базе данных лиц  $V$  наиболее похожий вектор  $\bar{y}$  и из найденной пары  $(\bar{y}, l)$  взять соответствующую ему фамилию  $l$ :

$l = \min_{(\bar{y} \in \bar{Y}) \& ((\bar{y}, l) \in V)} \|\bar{y} - y\|$  где  $l$  – фамилия распознанного человека по фотографии  $x$  ( $l \in L$ );  $\|\cdot\|$  – вычисление косинусного сходства векторов.

Таким образом, задача состоит в том, чтобы построить функционал  $f$ , на котором основана рассмотренная идея распознавания образов.

**Процесс распознавания лиц на кадрах из видеопотока.** Функциональная схема видеорегистрации студентов при входе в аудиторию с помощью компьютерного зрения показана на рис. 1.

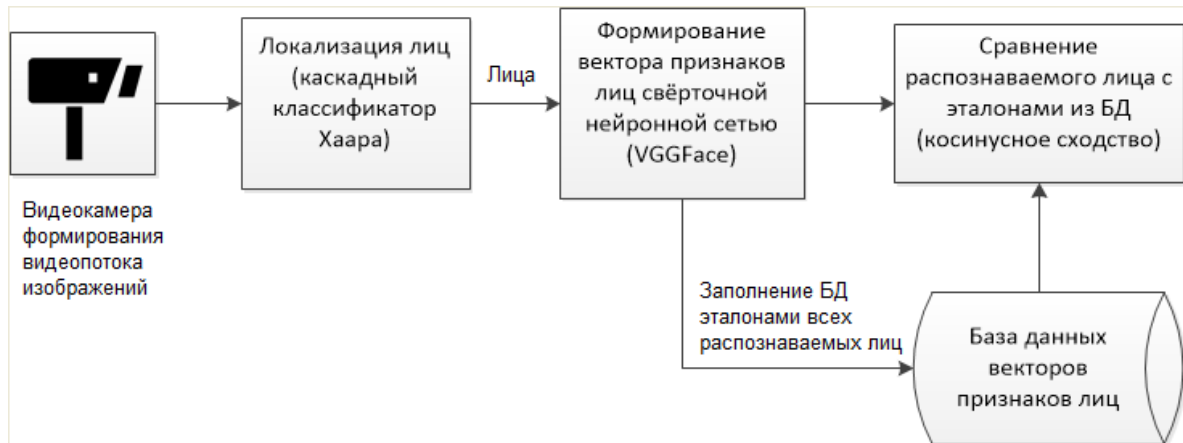


Рис. 1. Основные процессы компьютерного распознавания лиц

Блок обнаружения лиц принимает изображения с веб-камеры в режиме реального времени, выделяет и локализует на них лица. Эту функцию выполняет алгоритм детектирования лиц на текущем кадре видеопотока. В результате формируется последовательность изображений лиц, захватываемых видеокамерой, для последующего их распознавания.

Каждое выделенное изображение лица передаётся в блок формирования вектора признаков, который реализует распознавательную функцию  $f: X \rightarrow Y$ , где  $X$  – множество входных изображений лиц;  $Y$  – множество векторов признаков для лиц из  $X$ . Таким образом, нейросетевая функция  $f$  каждому выделенно-

му лицу  $x \in X$  ставит в соответствие вектор признаков  $y \in Y$  ( $y = f(x)$ ), которыми характеризуется данное лицо. Для выработки признаков лица применялась свёрточная нейронная сеть, которая предварительно была обучена на примерах фотографий 2622-х человек [2, 4, 5].

При настройке системы необходимо предварительно сформировать базу данных лиц  $V$  для всех распознаваемых людей, представленных конечным множеством соответствующих фамилий  $L$ . С этой целью для  $\forall \bar{x} \in \bar{X}$  с помощью нейросетевой распознавательной функции  $f$  определяется множество правильных пар  $V = \{(\bar{y}, l) | \bar{y} = f(\bar{x}), l \in L\}$ . Всё множество пар  $\{(\bar{y}, l)\}$  заносится в базу данных векторов признаков лиц (рис. 1).

В штатном режиме работы системы, т.е. при распознавании, в блоке сравнения вектор признаков  $y$  распознаваемого лица  $x$ , полученный с выхода свёрточной нейронной сети, сравнивается со всеми векторами  $\bar{y}$  базы данных  $V$ . Процедура сравнения основывается на методе вычисления косинусного сходства вектора распознаваемого лица с каждым вектором-эталон из базы данных лиц. Распознаваемое лицо считается соответствующим эталону, если полученный коэффициент сходства выше определённого значения (в работе использовалось значение 0.7).

**Архитектура свёрточной нейронной сети.** Многослойная архитектура свёрточной нейронной сети состоит из свёрточных слоёв (convolution layers) и субдискретизирующих слоёв (subsampling layers или pooling layers, слоёв подвыборки), которые чередуются друг с другом (рис. 2). В каждом слое имеется набор из нескольких плоскостей признаков. Изображение предыдущего слоя как бы сканируется небольшим окном, т.е. пропускается сквозь набор весов (ядро свёртки), и результат сканирования отображается на соответствующем нейроне текущего слоя. Ядро свёртки интерпретируют как графическое кодирование какого-либо признака. Таким образом, набор плоскостей представляет собой карты признаков (feature map), что позволяет каждой плоскости находить «свои» участки изображения в любом месте предыдущего слоя.

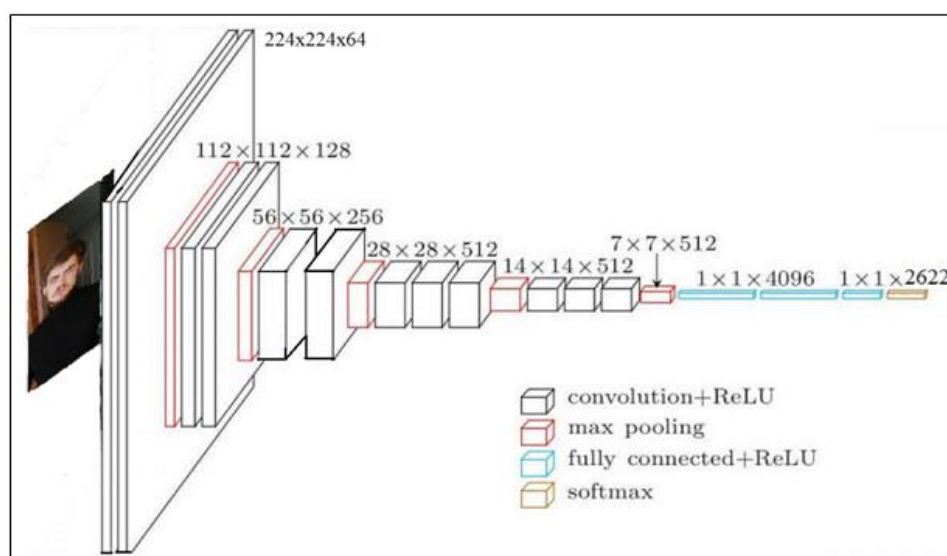


Рис. 2. Архитектура модели многослойной свёрточной нейронной сети VGGFace



Операция подвыборки (объединения), выполняет уменьшение размерности сформированных карт признаков. Чередование слоёв позволяет из предыдущих «карт признаков» составлять следующие «карты признаков», содержащие более общие характеристики, меньше зависящие от искажений изображения. На каждом следующем слое карта уменьшается в размере, но увеличивается их количество. На выходе свёрточных слоёв сети дополнительно устанавливается многослойный персептрон. Обучается сеть стандартным методом обратного распространения ошибки.

В системе видеоконтроля студентов в качестве модели свёрточной нейронной сети использовалась нейросеть VGGFace (рис. 2) [4, 5]. Сеть VGGFace принимает на входе RGB изображение лица размером 224x224 (фрагмент изображения, вырезанный по координатам, полученным методом Виолы-Джонса, расширяется или сжимается до этого размера). Далее изображения проходят через стек свёрточных слоёв, в которых используются фильтры с очень маленьким рецептивным полем размера 3x3.

Сеть предварительно обучена на множестве из 2,6 миллионов фотографий (2622 человека, 1000 фотографий каждого). Координаты каждого измерения вектора представляют собой вероятность того, что исходное лицо принадлежит одному из людей из обучающего множества.

Были проведены исследования качества распознавания и производительности системы. Для условий дневного света в помещении университета определены такие граничные значения способности распознавания, как углы поворота головы, уровень освещённости и расстояние до камеры. Распознавание с помощью указанной видеокамеры было устойчивым на расстоянии до 6 м от камеры. Эксперименты показали, что нейросеть распознавала изображения лиц даже размером 22x22 пикселя.

**Видеоконтроль присутствия студентов в аудитории.** При разработке системы использовались: язык программирования Python, фреймворк Qt5, СУБД SQLite, библиотеки NumPy, OpenCV, Keras, Hickie.

Задача автоматического учёта присутствия студентов на учебных занятиях включает следующие подзадачи:

- съёмка входящих в аудиторию студентов на видеокамеру;
- анализ кадров видеопотока на наличие лиц и их локализация;
- сравнение выделенных лиц с базой данных учащихся;
- отметка о присутствии на занятии (или опоздании) в случае успешной идентификации;
- сохранение данных в электронном журнале посещений.

В системе предусмотрен режим ручного редактирования электронного журнала. С помощью главного окна системы преподаватель может визуально наблюдать за процессом видеорегистрации и управлять информацией о студентах (рис. 3). В левой части окна высвечивается таблица со списком студентов группы, в которой преподаватель проводит занятие. Во время входа студента в аудиторию в таблице фиксируется время прибытия и его состояние (не отмечен, прибыл, опоздал, отсутствует).

В окне справа находятся элемент выбора дисциплины, кнопки остановить/продолжить распознавание, перехода в режим опоздания, сброса занятия и его завершения. По умолчанию все студенты в списке имеют статус «Не отмечен», а при распознавании обозначаются как «Присутствует». При переходе в режим опоздания (кнопка «Опоздание») статус всех неотмеченных студентов изменяется на «Отсутствует», а те, кто будет распознан в этом режиме, помечаются статусом «Опоздание».

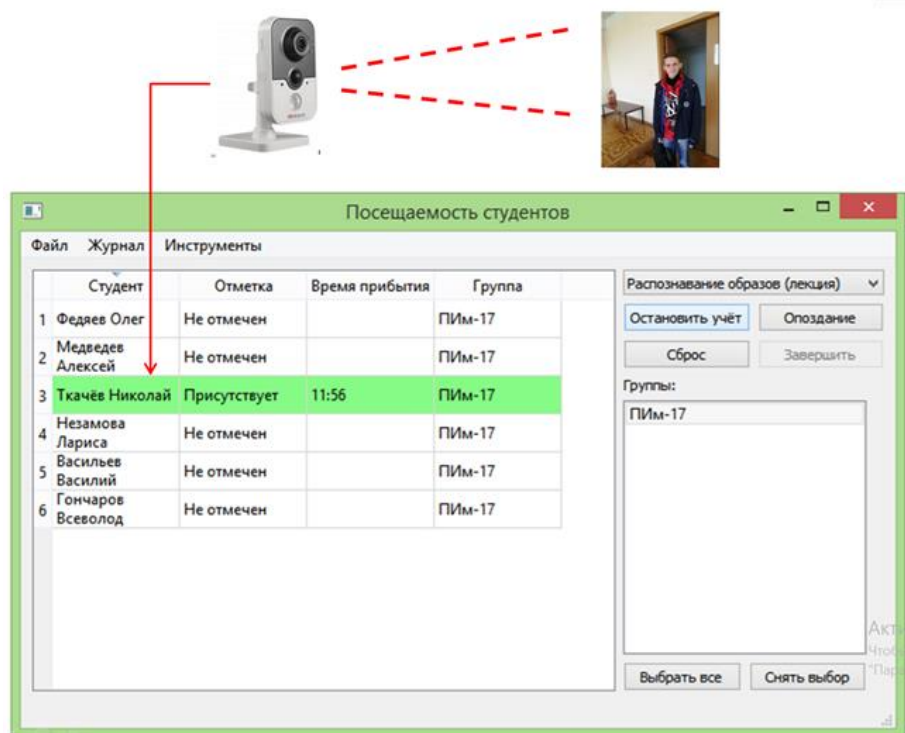


Рис. 3. Главное окно системы регистрации студентов

Пункты главного меню предоставляют преподавателю дополнительный сервис управления студентами: добавление (изменение) имён студентов и удаление групп; отображение студентов по группам, добавление, редактирование и удаление студентов; изменение группы студентов; добавление и изменение фотографии (фотография может быть выбрана из файла либо с камеры).

При нажатии кнопки «Завершить» прекращается визуальная регистрация студентов и данные записываются в общий электронный журнал. Электронный журнал представляет собой реляционную таблицу, содержащую фамилии студентов, дату проведения занятия, предмет, группу, отметки о присутствии.

**Заключение.** В работе реализован подход к решению задачи распознавания лица человека на основе свёрточной нейронной сети, позволивший с помощью компьютерного зрения устранить потери времени преподавателя, которые возникают при ручной регистрации присутствия большого количества учащихся в аудитории. Локализация лиц на кадрах с видеокамеры выполнена методом Виола-Джонса. Свёрточная нейронная сеть формирует признаки лица человека. Идентификация личности происходит вычислением косинусного коэффициента сходства векторов признаков лиц. Процесс распознавания реализован в режиме реального времени.

Компьютерная система может быть установлена на ноутбуке преподавателя и выполнять не только оперативный учёт присутствия студентов на занятиях, но и стать платформой для реализации других функций контроля проведения учебных занятий.

### Библиографический список

1. Deep Learning – Wikipedia [Электронный ресурс] – Режим доступа: [https://en.wikipedia.org/wiki/Deep\\_learning](https://en.wikipedia.org/wiki/Deep_learning)
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.
3. Федяев О.И., Махно Ю.С. Система распознавания зашумлённых и искажённых графических образов на основе нейронной сети типа неокогнитрон // Одиннадцатая национальная конференция по искусственному интеллекту с международным участием КИИ-2008: Труды конференции. Т. 3. – М.: ЛЕНАНД, 2008. – С. 75-83.
4. Антонио Джулли, Суджит Пал. Библиотека Keras – инструмент глубокого обучения. Реализация нейронных сетей с помощью библиотек Theano и TensorFlow / пер. с англ. Слинкин А.А. – М.: ДМК Пресс, 2018. – 294 с.
5. VGG Face Descriptor [Электронный ресурс] // [robots.ox.ac.uk](http://robots.ox.ac.uk/~vgg/software/vgg_face/) . – Режим доступа: [http://www.robots.ox.ac.uk/~vgg/software/vgg\\_face/](http://www.robots.ox.ac.uk/~vgg/software/vgg_face/)

## NEURAL NETWORK FACE RECOGNITION IN THE VIDEO STREAM OF THE AUTOMATIC CONTROL SYSTEM FOR THE PRESENCE OF STUDENTS IN THE CLASSROOM

***Oleg I. Fedyaev***

Donetsk National Technical University,  
Str. Artema, 58, Donetsk, DPR, Russia, 283001  
[olegfedyayev@mail.ru](mailto:olegfedyayev@mail.ru)

***Anton A. Sukhanov***

Donetsk National Technical University,  
Str. Artema, 58, Donetsk, DPR, Russia, 283001  
[studysukhanov@mail.ru](mailto:studysukhanov@mail.ru)

The problem of video recording the presence of students in the classroom is considered. Face recognition of students is carried out in real time using the convolutional neural network of the VGGFace model. The video monitoring system captures the faces of students on a video camera at the entrance to the room, compares the faces with the database of students, notes their presence at the lecture (or lateness) and, in case of successful identification, saves the data in an electronic journal. When conducting lectures with a large number of students, this system will allow you to automate the accounting of the presence of students in classrooms and accumulate statistical data on the academic discipline of each student during the semester.

**Keywords:** computer vision, convolutional neural network, face recognition, video stream, registration of students in the classroom.

## РАЗВИТИЕ ИИ-ГРАМОТНОСТИ И КРИТИЧЕСКОГО МЫШЛЕНИЯ

***Попов Богдан Сергеевич***

Донецкий национальный технический университет,  
283001, Россия, ДНР, г. Донецк, ул. Артёма, 58  
Popov.Bogdan.97@yandex.ru

В статье исследуются методы развития ИИ-грамотности и критического мышления у студентов. Рассматриваются современные подходы к обучению и анализируется эффективность использования искусственного интеллекта в образовательном процессе. Приводятся примеры успешной интеграции ИИ в образование, демонстрирующие его влияние на подготовку студентов к работе в цифровом обществе.

**Ключевые слова:** искусственный интеллект (ИИ), ИИ-грамотность, критическое мышление, образовательные технологии, методы обучения, внедрение ИИ.

**Введение.** В современном мире, где технологии развиваются с невероятной скоростью, искусственный интеллект (ИИ) становится неотъемлемой частью нашей повседневной жизни. В связи с этим, образовательные учреждения сталкиваются с новой задачей – подготовкой студентов к жизни и работе в условиях, где ИИ играет ключевую роль. Развитие ИИ-грамотности и критического мышления становится важным аспектом образовательного процесса, способствующим формированию компетенций, необходимых для успешной адаптации в цифровом обществе.

ИИ-грамотность включает в себя понимание основ ИИ, его возможностей и ограничений, а также умение использовать ИИ-технологии для решения различных задач. В свою очередь, критическое мышление позволяет студентам анализировать информацию, оценивать её достоверность и принимать обоснованные решения. Эти навыки взаимосвязаны и дополняют друг друга, создавая прочную основу для успешного обучения и профессиональной деятельности.

Цель данного исследования – определить ключевые аспекты и методы развития ИИ-грамотности и критического мышления у студентов. В рамках исследования будут рассмотрены современные подходы к обучению ИИ, а также методы, способствующие развитию критического мышления. Особое внимание будет уделено анализу эффективности внедрения ИИ в образовательный процесс и его влиянию на качество обучения.

Задачи исследования включают:

1. Анализ текущего состояния ИИ-грамотности в образовательных учреждениях.
2. Изучение методов и инструментов для развития критического мышления.
3. Оценка эффективности внедрения ИИ в образовательный процесс.
4. Разработка практических рекомендаций для образовательных учреждений и преподавателей по интеграции ИИ-грамотности и критического мышления в учебные программы.

Актуальность данной темы обусловлена растущей ролью ИИ в различных сферах жизни и необходимости подготовки студентов к работе в условиях циф-

ровой экономики. Развитие ИИ-грамотности и критического мышления позволит не только повысить качество образования, но и подготовить студентов к успешной профессиональной деятельности в будущем.

**Анализ литературы.** В рамках анализа были изучены статьи по теме ИИ-грамотности и критического мышления, опубликованные в ведущих научных журналах, таких как “Research in Science Education” и “TechTrends”. Особое внимание уделялось исследованиям, опубликованным в последние годы, чтобы обеспечить актуальность и современность полученных данных. Анализ литературы позволил выявить основные тенденции и подходы к развитию ИИ-грамотности и критического мышления, а также определить пробелы в существующих исследованиях.

**Определение ИИ-грамотности.** ИИ-грамотность представляет собой совокупность знаний и навыков, необходимых для понимания и эффективного использования технологий искусственного интеллекта. Включает в себя базовые понятия ИИ, такие как машинное обучение, нейронные сети, алгоритмы и их применение в различных сферах. Важно, чтобы студенты не только знали, как работают эти технологии, но и понимали их потенциал и ограничения. Это позволяет им критически оценивать информацию, получаемую с помощью ИИ, и принимать обоснованные решения. ИИ-алгоритмы играют ключевую роль в персонализации образовательного процесса и улучшении академических результатов [1].

**Критическое мышление.** Критическое мышление – это способность анализировать, оценивать и синтезировать информацию для принятия обоснованных решений. В контексте ИИ критическое мышление помогает студентам не только понимать, как работают алгоритмы, но и оценивать их результаты с точки зрения достоверности и этичности. Развитие критического мышления способствует формированию у студентов навыков, необходимых для решения сложных задач и адаптации к быстро меняющемуся миру. Для успешного использования ИИ в образовательных учреждениях важно развитие критического мышления [2].

**Связь между ИИ-грамотностью и критическим мышлением.** ИИ-грамотность и критическое мышление тесно связаны между собой, развитие одного способствует развитию другого. Например, изучение основ ИИ требует от студентов критического подхода к анализу данных и алгоритмов. В свою очередь, критическое мышление помогает студентам лучше понимать и использовать ИИ-технологии. Таким образом, интеграция ИИ-грамотности и критического мышления в образовательный процесс позволяет создать более комплексное и эффективное обучение.

**Современные подходы к обучению.** Современные подходы к обучению ИИ-грамотности включают использование различных образовательных платформ и онлайн-курсов, которые предоставляют студентам доступ к актуальной информации и инструментам. Важную роль играют также практические занятия, где студенты могут применять полученные знания на практике. Например, создание собственных проектов с использованием ИИ помогает студентам лучше понять, как работают технологии и как их можно применять для решения реальных задач [3].

**Анализ текущего состояния ИИ-грамотности.** Анализ текущего состояния ИИ-грамотности показывает, что это становится все более важным аспектом современного образования, особенно в свете быстрого развития технологий искусственного интеллекта и их проникновения в различные сферы жизни. Важно понимать, как современные подходы к развитию ИИ-грамотности влияют на студентов и преподавателей, а также как они могут быть использованы для повышения качества образования.

Исследование [9], предоставило ценные данные о представлениях студентов университета об ИИ-грамотности. С использованием анкетного метода и последующего тематического анализа было выявлено, что студенты рассматривают этические принципы как ключевой компонент ИИ-грамотности. Это подчёркивает необходимость пересмотра традиционных подходов к обучению искусственному интеллекту, направляя их в сторону более комплексного понимания, включающего этические и социальные аспекты использования ИИ.

Кроме того, исследования показывают, что применение генеративных ИИ-инструментов и кибер-социальных методов обучения значительно способствует развитию ИИ-грамотности у студентов высших учебных заведений. Важной задачей педагогов становится обучение студентов самостоятельной работе с ИИ, включая его применение в профессиональной деятельности. Такой подход не только усиливает технические навыки, но и способствует формированию у студентов способности к критическому анализу и оценке информации, получаемой с использованием ИИ [11].

Результаты исследований ясно указывают на важность интеграции искусственного интеллекта в образовательный процесс. Подготовка студентов к жизни и работе в условиях цифровой экономики требует не только обучения техническим навыкам, но и развития критического мышления, понимания этических аспектов и способности анализировать информацию. Текущий анализ состояния ИИ-грамотности свидетельствует о наличии множества подходов и инструментов для её эффективного развития [9].

Таким образом, интеграция ИИ в образовательный процесс является ключевым фактором в подготовке студентов к современным условиям работы и жизни.

**Методы и инструменты развития ИИ-грамотности.** Развитие ИИ-грамотности у студентов требует использования разнообразных методов и инструментов, которые позволяют интегрировать ИИ в образовательный процесс. Одним из эффективных методов является использование образовательных платформ и онлайн-курсов, таких как Coursera, edX и Khan Academy, которые предлагают курсы по основам ИИ и машинного обучения. Эти платформы предоставляют студентам доступ к актуальной информации и позволяют изучать ИИ в удобном для них темпе.

**Методы развития критического мышления.** Для развития критического мышления используются различные методы, такие как дискуссии, дебаты, анализ и решение проблемных ситуаций. Важно, чтобы студенты имели возможность высказывать свои мнения, аргументировать их и критически оценивать точки зрения других. Использование ИИ для создания интерактивных заданий и симуляций также способствует развитию критического мышления, так как позволяет студентам анализировать и оценивать результаты своей работы [4].

**Примеры успешного внедрения.** Во всем мире образовательные учреждения активно внедряют искусственный интеллект (ИИ) в свои программы, достигая при этом впечатляющих результатов.

Например, ещё в 2018 году Walden University в партнёрстве с Google Cloud разработал онлайн-репетитора на основе ИИ, известного как Julian. Этот инструмент предоставляет круглосуточную персонализированную поддержку студентам, помогая им закреплять изученные материалы и выявлять пробелы в обучении. Julian создаёт новый набор заданий при каждом взаимодействии студента и сохраняет заметки, к которым можно обратиться на протяжении всей учебной программы [6].

Другой пример – чат-бот Khanmigo, разработанный для системы персонализированного обучения. Используя адаптивные методы, он предоставляет студентам доступ к репетитору на базе ИИ, а преподавателям – к ассистенту для оптимизации процесса обучения. Кроме того, Khanmigo позволяет студентам вести диалог с историческими личностями и литературными персонажами, созданными искусственным интеллектом, такими как Джордж Вашингтон и Гамлет [6].

Университет штата Джорджия внедрил чат-бот Rounce, первоначально предназначенный для помощи студентам при поступлении в колледж в вопросах финансирования и регистрации. Однако Rounce также продемонстрировал эффективность в повышении академической успеваемости. Студенты, получавшие сообщения о заданиях, академической поддержке и содержании курса через Rounce, чаще получали оценки B и выше. Особенно заметен этот эффект был среди студентов первого поколения иммигрантов, чьи итоговые оценки улучшились на 11 баллов по сравнению со сверстниками [6].

В Политехническом университете штата Калифорния, Помона, с помощью ИИ-платформы Packback преподаватели смогли повысить качество письменных работ и уровень вовлеченности студентов. Ранее студенты зачастую просто повторяли материал из учебников в своих вопросах и ответах. Теперь же они пишут от 5 до 7 абзацев продуманных вопросов и ответов, анализируя первоисточники и создавая новые идеи. Packback также предлагает функцию Writing Lab для интерактивного обучения письму, что способствует развитию грамотности в использовании ИИ [6].

Ещё один пример успешного использования ИИ – Университет Мурсии в Испании, где внедрили чат-бот Lola для помощи студентам в вопросах о кампусе и академических программах. Lola продемонстрировал высокий уровень эффективности, ответив на 38 708 вопросов правильно более чем в 91% случаев. Использование такого чат-бота позволило университету не только предоставлять круглосуточную поддержку студентам, но и высвободить время сотрудников для других задач [7].

Университет Nova Southeastern во Флориде применил технологию Aible, основанную на ИИ, для анализа имеющихся данных и повышения уровня удержания студентов. Программное обеспечение помогло выявить студентов, которые с наибольшей вероятностью покинут университет, чтобы направить усилия на их поддержку и снизить процент отсева. В результате использования Aible университет за 15 дней добился снижения отсева студентов на 17% [6].

Эти примеры демонстрируют, как использование искусственного интеллекта в образовании может не только повысить эффективность обучения, но и способствовать развитию ключевых навыков у студентов.

**Практические рекомендации.** Образовательным учреждениям рекомендуется включить основы ИИ и его применение в учебные программы. Это позволит студентам не только ознакомиться с техническими аспектами, но и понять этические и социальные последствия использования ИИ. Программы могут быть интегрированы в уже существующие курсы или представлены в виде отдельных модулей.

Важно также включить в учебный процесс элементы дискуссий и дебатов на тему использования ИИ. Это поможет студентам развить навыки критического мышления, необходимые для анализа и оценки информации, полученной с использованием ИИ. Такие методы стимулируют студентов к рассмотрению этических аспектов и потенциальных рисков, связанных с ИИ.

Для эффективного внедрения ИИ в образовательный процесс необходимо проводить обучение преподавателей. Они должны обладать необходимыми знаниями и навыками для использования и интеграции ИИ-технологий в своих курсах. Проведение семинаров и мастер-классов поможет педагогам освоить современные инструменты и методы обучения с использованием ИИ.

Наконец, рекомендуется внедрять системы мониторинга и оценки эффективности использования ИИ в образовательном процессе. Это позволит выявить сильные и слабые стороны текущих методов обучения и своевременно корректировать подходы, чтобы обеспечить максимальное качество образования.

**Заключение.** В условиях стремительного развития технологий искусственного интеллекта (ИИ) образовательные учреждения сталкиваются с необходимостью подготовки студентов к жизни и работе в цифровом обществе. Развитие ИИ-грамотности и критического мышления становится ключевым аспектом образовательного процесса, способствующим формированию компетенций, необходимых для успешной адаптации к новым условиям.

В ходе данного исследования были рассмотрены основные аспекты ИИ-грамотности и критического мышления, их взаимосвязь и современные подходы к их развитию в образовательных учреждениях. Анализ литературы позволил получить картину текущего состояния ИИ-грамотности, а также оценить эффективность различных методов их развития.

Результаты исследования показали, что использование образовательных платформ и онлайн-курсов, способствует развитию ИИ-грамотности у студентов. Методы развития критического мышления, такие как дискуссии, дебаты и анализ проблемных ситуаций, показали свою эффективность в формировании у студентов способности к анализу и оценке информации.

Примеры успешного внедрения ИИ-технологий в образовательных учреждениях, рассмотренные в исследовании, показали значительное улучшение учебных результатов и повышение уровня вовлеченности студентов. Использование чат-ботов, онлайн-репетиторов и адаптивных систем обучения на основе ИИ способствует индивидуализации учебного процесса и обеспечивает постоянную поддержку студентов.



Таким образом, развитие ИИ-грамотности и критического мышления является важным аспектом современного образования, способствующим подготовке студентов к работе в условиях цифровой экономики. Результаты исследования могут быть использованы для разработки рекомендаций по улучшению образовательного процесса и подготовки студентов к будущей профессиональной деятельности.

### Библиографический список

1. Gligorea I, Cioca M, Oancea R, Gorski A-T, Gorski H, Tudorache P. Adaptive Learning Using Artificial Intelligence in e-Learning: A Literature Review. *Education Sciences*. 2023; 13(12):1216. <https://doi.org/10.3390/educsci13121216>
2. Walter, Y. Embracing the future of Artificial Intelligence in the classroom: the relevance of AI literacy, prompt engineering, and critical thinking in modern education. *Int J Educ Technol High Educ* 21, 15 (2024). <https://doi.org/10.1186/s41239-024-00448-3>
3. Yim, I.H.Y., Su, J. Artificial intelligence (AI) learning tools in K-12 education: A scoping review. *J. Comput. Educ.* (2024). <https://doi.org/10.1007/s40692-023-00304-9>
4. Memarian, B., Doleck, T. Teaching and learning artificial intelligence: Insights from the literature. *Educ Inf Technol* (2024). <https://doi.org/10.1007/s10639-024-12679-y>
5. Almasri, F. Exploring the Impact of Artificial Intelligence in Teaching and Learning of Science: A Systematic Review of Empirical Research. *Res Sci Educ* **54**, 977–997 (2024). <https://doi.org/10.1007/s11165-024-10176-3>
6. 8 Universities Leveraging AI to Drive Student Success | Digital Marketing Institute. [Электронный ресурс]. Режим доступа: <https://digitalmarketinginstitute.com/blog/8-universities-leveraging-ai-to-drive-student-success>
7. How Effective is AI in Education? 10 Case Studies and Examples. [Электронный ресурс]. Режим доступа: <https://axonpark.com/how-effective-is-ai-in-education-10-case-studies-and-examples/>
8. Lintner, T. A systematic review of AI literacy scales. *npj Sci. Learn.* **9**, 50 (2024). <https://doi.org/10.1038/s41539-024-00264-4>
9. Černý M. University Students' Conceptualisation of AI Literacy: Theory and Empirical Evidence. *Social Sciences*. 2024; 13(3):129. <https://doi.org/10.3390/socsci13030129>
10. Černý, M. (2024). AI Literacy in Higher Education: Theory and Design. In: Tomczyk, Ł. (eds) *New Media Pedagogy: Research Trends, Methodological Challenges, and Successful Implementations*. NMP 2023. Communications in Computer and Information Science, vol 2130. Springer, Cham. [https://doi.org/10.1007/978-3-031-63235-8\\_24](https://doi.org/10.1007/978-3-031-63235-8_24)
11. Tzirides, A. O., Zapata, G., Kastania, N. P., Saini, A. K., Castro, V., Ismael, S. A., You, Y., Santos, T. A. D., Searsmith, D., O'Brien, C., Cope, B., & Kalantzis, M. (2024). Combining human and artificial intelligence for enhanced AI literacy in higher education. *Computers and Education Open*, 6, Article 100184. <https://doi.org/10.1016/j.caeo.2024.100184>

## DEVELOPMENT OF AI-GRAMMATISM AND CRITICAL THINKING

**Bogdan S. Popov**

Donetsk National Technical University,  
Str. Artyoma, 58, Donetsk, Russia, DPR, 283001

[Popov.Bogdan.97@yandex.ru](mailto:Popov.Bogdan.97@yandex.ru)

The article explores methods of developing AI-literacy and critical thinking in students. The article considers modern approaches to teaching and analyses the effectiveness of using artificial intelligence in the educational process. Examples of successful integration of AI in education are given, demonstrating its influence on students' preparation for work in the digital society.

**Keywords:** artificial intelligence (AI), AI-literacy, critical thinking, educational technologies, teaching methods, AI implementation.

## ГЕНЕРАТИВНЫЕ И АДАПТИВНЫЕ МОДЕЛИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В РЕШЕНИИ ОБРАЗОВАТЕЛЬНЫХ ЗАДАЧ

*Орлова Татьяна Сергеевна*

Санкт-Петербургская государственная художественно-промышленная академия  
им. А. Л. Штиглица,  
191028, Россия, г. Санкт-Петербург, Соляной пер., 13  
ots\_prof@mail.ru

Рассматриваются актуальные вопросы использования искусственного интеллекта (ИИ) в образовательной сфере, с особым акцентом на языковые модели, такие как ChatGPT и аналогичные платформы. Анализируется влияние этих технологий на академическую честность и навыки работы с текстом. Обсуждаются возможности и риски, связанные с использованием ИИ для создания учебных материалов и поддержки образовательного процесса. Освещаются проблемы, такие как плагиат, ухудшение навыков текстовой работы, защита персональных данных и возможные алгоритмические предвзятости. Статья также предлагает пути интеграции ИИ в образовательные процессы для повышения эффективности и доступности обучения.

**Ключевые слова:** искусственный интеллект, образовательные технологии, языковые модели, ChatGPT, академическая честность, защита данных, плагиат, алгоритмическая предвзятость, интеграция ИИ в образование, автоматизированные образовательные системы.

**Введение.** Прогресс в области искусственного интеллекта стимулировал ускоренное распространение языковых моделей. В ноябре 2022 года компания OpenAI представила ChatGPT – чат-бота, способного создавать тексты и изображения, отвечать на вопросы, а также помогать с идеями для текстов. После этого на рынке появились другие аналогичные продукты, включая российские разработки YandexGPT и GigaChat, а также китайский Ernie. В 2024 году AI встроены не только в браузеры, но и в ПО смартфонов, а также в веб-сервисы электронной почты.

**Постановка проблемы.** В контексте быстрого прогресса и активного внедрения генеративных моделей ИИ, система высшего образования столкнулась с необходимостью адаптировать эти технологии. Одновременно возникли сложности, такие как борьба с плагиатом, ухудшение навыков работы с текстом и литературой, а также вопросы, связанные с защитой персональных данных, нарушением авторских прав и рисками алгоритмической или политической предвзятости в нейросетевых моделях.

**Исследование проблемного поля.** Создание текстов студентами с помощью ИИ представляет потенциальный риск для академической честности и формирования навыков, особенно когда речь идет о языковых курсах, требующих интенсивного письма, в том числе в сфере международных исследований и гуманитарных дисциплин в целом. Кроме того, интеграция текста, созданного искусственным интеллектом, в текст написанный самостоятельно может приве-

сти к академическим неточностям и погрешностям, поскольку чат-бот нередко допускает ошибки.

**Описание проблемного поля.** Существует несколько основных типов запросов, при написании которых искусственный интеллект чаще всего ошибается. Искусственный интеллект часто ошибается по причине того, что его ответы строятся на уже заложённой информации, но запрограммированные тексты не всегда могут быть полными или точными. ChatGPT не имеет доступа к интернету в реальном времени, поэтому он не может обновлять свои знания или отслеживать актуальные изменения и события, так что некоторая информация может быть устаревшей или вообще придуманной. Ещё одной причиной ошибок является то, что языковая модель иногда "недопонимает" контекст запроса, особенно если он сложный или двусмысленный. Помимо этого, модель может генерировать ответы, которые кажутся логичными, но фактически содержат выдуманные или искажённые данные. Поэтому всегда написанный текст следует перепроверять и сопоставлять с фактами из литературы, Интернета, а также с собственными расчетами, если дело касается их. При этом генеративные и адаптивные модели искусственного интеллекта (кроме ChatGPT) обладают огромным потенциалом в сфере образования и нельзя недооценить их полезность и эффективность. Рассмотрим некоторые из возможных путей использования искусственного интеллекта.

Системы-наставники особенно актуальны для школьников и студентов, стремящихся углубить и проверить свои знания в определённых дисциплинах. Такие системы позволяют задавать вопросы по интересующим темам, получать разъяснения сложных моментов в доступной форме, участвовать в научных дискуссиях и обращаться за помощью при решении сложных задач, что делает их незаменимым инструментом в образовательном процессе.

На платформе Character AI представлен широкий спектр тьюторов, удовлетворяющий самые разнообразные запросы пользователей. Изначально созданная для текстовых ролевых игр и взаимодействия с фиктивными персонажами из видеоигр, комиксов и сериалов, сегодня платформа также включает в себя специализированных ботов из различных профессиональных сфер, включая ученых и авторов разнообразных методик. Например, здесь можно найти виртуальное представление такой исторической личности, как Исаак Ньютон, и задать ему вопросы.

Кроме того, платформа предлагает возможность создать виртуальное отображение реального педагога. Для этого достаточно загрузить фотографию преподавателя и указать в описании бота его основные характеристики, включая специализацию и ключевые черты поведения. Это открывает новые перспективы для университетов и образовательных организаций в создании персонализированных образовательных ассистентов, доступ к которым возможен для любого пользователя и абсолютно бесплатно.

Компания Google разработала приложение под названием Socratic, которое анализирует и предлагает решения для задач, с которыми студенты сталкиваются, используя всего лишь одну фотографию. Тем временем, Khan Academy внедрила на своей платформе виртуального наставника по имени Khanmigo, ко-

торый работает на основе GPT-4. Этот инструмент поддерживает учителей, студентов и их родителей на всех этапах обучения, отвечая на вопросы, предоставляя подсказки и оценивая результаты.

Однако существует один существенный недостаток в использовании компьютеризированных систем для образовательных целей, о которых мы писали ранее: языковые модели иногда демонстрируют так называемые «галлюцинации», потому необходима тщательная проверка фактов.

Тем не менее, анализ успеваемости с целью своевременного коррективного вмешательства может оказаться крайне полезным в образовательной сфере. Под «ранним вмешательством» понимают действия, направленные на стабилизацию успеваемости учащихся до того момента, как у них начнут формироваться пробелы в знаниях, понижаться баллы и возникать трудности с усвоением материала. Это может быть корректировка образовательной траектории ученика, замену неэффективных методов и форм обучения на более подходящие, а также изменения в расписании и методах оценивания [2].

Когда ученик или педагог самостоятельно предпринимает такие действия, то инициатива по идентификации нуждающихся в дополнительной поддержке или репетиторстве выполняется на основе непрерывного мониторинга и анализа успеваемости каждого студента. Это позволяет определить учащихся, которые могут находиться в «группе риска». BrightBytes и Renaissance Star 360 интегрируются с учебной базой данных, содержащей результаты тестов, оценки и другую релевантную информацию о студентах, формируя рейтинги успеваемости и предоставляя данные для прогнозирования и раннего вмешательства [6].

Платформы с адаптивным ИИ, например Smart Sparrow и Docebo, позволяют разработать индивидуальные учебные планы для освоения любых направлений, отталкиваясь от профиля пользователя и информации о нем (его успеваемости, предпочтениях, привычном темпе обучения и т.д.). И здесь Google тоже приняла участие, создав, например, Illuminate, который за считанные минуты преобразует длинные научные статьи в короткие подкасты при помощи сгенерированных ИИ голосов. Так, с Illuminate можно не читать научные трактаты, а слушать, причем прямо в дороге или во время выполнения рутинных задач. При этом важно отметить, что Illuminate не просто озвучивает текст, а превращает его в полноценную научную беседу, используя два голоса, которые делают подачу материала более динамичной, как если бы тему рассказывали настоящие ведущие.

Также Learn About, который преобразует любой материал в любой формат, представляется удобным для применения. Так, один и тот же текст можно превратить в цепочку слайдов, графики, видео, веб-страницы, quiz-карточки или задания. В процессе пользователь также может взаимодействовать с форматами, задавать встроенному боту уточняющие вопросы, дополняя таким образом материал, или делать к нему пометки.

**Заключение.** Цифровизация в сфере высшего образования способствует возникновению новых форматов и возможностей, благодаря которым удалось компенсировать ряд недостатков и усилить преимущества [1]. В современном образовательном пространстве автоматизированные системы поддержки обу-

чения играют всё более значимую роль. Хотя они не могут полностью заменить преподавателей, их применение в качестве наставников и помощников студентам оказывается крайне перспективным. Преимущества таких систем многочисленны: они доступны круглосуточно, не испытывают усталости, не требуют перерывов и выходных. Большинство из них предоставляются бесплатно, что делает их доступными для широкой аудитории пользователей, в то время как услуги опытных профессионалов могут быть довольно затратными.

### Библиографический список

1. Алексеева К.В., Вергелес К.П., Захаров А.Б., Карной М., Ларина Г.С., Маркина В.М. и др. Восприятие контингента. (Не)обычные школы: разнообразие и неравенство: монография. М.: НИУ ВШЭ; 2019. 232 с.
2. Алтухова Е.В. Наука и высшее образование в системе цифровизации экономики. В кн.: Национальные экономики в условиях глобальных и локальных трансформаций: сборник статей международной научно-практической конференции, Москва, 23–28 октября 2018 г. М.: НИИ ИЭП; 2018. С. 7–10.
3. Билялова Л.Р., Стрыгин А.В. Особенности технологии удаленных занятий в вузах. Финансовый бизнес. 2020. № 3. С. 3–8.
4. Воронина А.А. Трудовые аспекты организации дистанционного обучения в вузах. Вопросы трудового права. 2020. № 10.
5. Зубок Ю.А., Чупров В.И., Любутов А.С., Сорокин О.В. Жизненные позиции молодежи: смысловые основания формирования. Вестник Института социологии. 2021. № 3. С. 79–98.
6. Зиновьева Е., Трапезников В. Нейросети и генеративный ИИ в высшем образовании: международный опыт и российская практика [Электронный ресурс] // РСМД. Режим доступа: [https://russiancouncil.ru/analytics-and-comments/analytics/neuroseti-generativnyy-ii-v-vysshem-obrazovanii-mezhdunarodnyy-opyt-i-rossiyskaya-praktika/?sphrase\\_id=153572900](https://russiancouncil.ru/analytics-and-comments/analytics/neuroseti-generativnyy-ii-v-vysshem-obrazovanii-mezhdunarodnyy-opyt-i-rossiyskaya-praktika/?sphrase_id=153572900) (дата обращения: 17.09.2024).
7. Юдина Т.Н., Сёмочкина Н.Н. Постпандемия: итоги и перспективы цифровизации высшего образования//Цифровая социология. 2024. № 1. С. 86–96.

## GENERATIVE AND ADAPTIVE MODELS OF ARTIFICIAL INTELLIGENCE IN SOLVING EDUCATIONAL PROBLEMS

*Tatiana S. Orlova*

St. Petersburg Stieglitz State Academy of Art and Design,  
Solyanoi Lane, 13, St. Petersburg, Russia, 191028  
[ots\\_prof@mail.ru](mailto:ots_prof@mail.ru)

The current issues of the use of artificial intelligence (AI) in the educational field are considered, with a special focus on language models such as ChatGPT and similar platforms. The impact of these technologies on academic integrity and text skills is analyzed. The possibilities and risks associated with using AI to create educational materials and support the educational process are discussed. Problems such as plagiarism, deterioration of textual skills, protection of personal data and possible algorithmic biases are highlighted. The article also suggests ways to integrate AI into educational processes to improve the effectiveness and accessibility of learning.

**Keywords:** artificial intelligence, educational technologies, language models, ChatGPT, academic integrity, data protection, plagiarism, algorithmic bias, integration of AI into education, automated educational systems.

## ВАРИАТИВНОЕ ОБУЧЕНИЕ ОСНОВАМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ШКОЛЬНОМ КУРСЕ ИНФОРМАТИКИ

*Самылкина Надежда Николаевна*

Московский педагогический государственный университет,  
614068, Россия, г. Москва, ул. Малая Пироговская, 1  
nsamylkina@yandex.ru

В статье представлены результаты исследования, посвященные разработке методики вариативного обучения основам искусственного интеллекта (ИИ) и анализа данных в курсе информатики основного общего и среднего общего образования с учетом внеурочной и проектно-исследовательской деятельности обучающихся в соответствии с требованиями обновленного ФГОС ОО на основе интегративного методологического подхода.

**Ключевые слова:** искусственный интеллект, анализ данных, вариативное обучение, интегративный подход, обновленный ФГОС общего образования, внеурочная деятельность, проектная деятельность.

**Введение.** Для последнего десятилетия характерно активное использование технологий искусственного интеллекта в профессиональной деятельности, системе образования разных уровней, принятие государственных программ, связанных с развитием ИИ и анализом больших данных. На тематику изучения основ искусственного интеллекта и анализа данных ориентируется школьный курс информатики, начиная с использования технологий искусственного интеллекта в основном общем образовании до теоретических и практических основ в содержании информатики углубленного уровня среднего общего образования. Несмотря на имеющиеся исследования о возможностях искусственного интеллекта, его методов и алгоритмов, а также широкое применение анализа данных в различных профессиональных областях, можно констатировать, что пока недостаточно научно обоснованных методических подходов к системному изучению вопросов искусственного интеллекта в общем образовании. Существуют разные мнения по отбору содержательного контента для включения школьные в учебники информатики и учебные пособия, по выбору инструментальных средств реализации интеллектуальных алгоритмов, ощущается серьезная нехватка учебно-методического обеспечения, в том числе цифрового, для основной и старшей школы [2; 3; 5; 7; 9]. В условиях сохранения единого содержания общего образования, обновления подходов к формированию и оцениванию образовательных результатов существует потребность в существенном обновлении содержания курса информатики за счет интеграции изучаемых тем с тематикой и технологиями ИИ и анализа данных для возможного построения различных образовательных траекторий при получении общего образования.

---

© Самылкина Н.Н., 2024

Работа выполнена в рамках государственного задания Министерства просвещения Российской Федерации (тема № 124052100092-0 («Вариативное обучение основам искусственного интеллекта в общем образовании на основе интегративного подхода»)).

The research was carried out within the state assignment of The Ministry of Education of The Russian Federation (theme № 124052100092-0).

**Постановка цели исследования.** Целью представленного исследования является разработка научно-методического обеспечения вариативного обучения основам искусственного интеллекта в курсе информатики, во внеурочной и проектно-исследовательской деятельности обучающихся основного общего и среднего общего образования на основе интегративного подхода в соответствии с требованиями обновленного ФГОС общего образования. Результаты исследования необходимы для проектирования траекторий вариативного обучения основам искусственного интеллекта в школьном курсе информатики.

**Методология исследования.** Для разработки методики обучения основам искусственного интеллекта и анализа данных в курсе информатики основного общего и среднего общего образования использовались теоретические и эмпирические методы исследования. Был проведен анализ научных публикаций по тематике искусственного интеллекта, анализ и сравнение материалов зарубежных образовательных стандартов различных уровней образования, обзор отечественных практик внедрения результатов педагогических исследований по методике обучения информатике на основе интегративного методологического подхода [3; 5; 7; 9; 10; 11].

Опираясь на положения концепции методической системы углубленного обучения информатике на основе интегративного подхода [6] и методику обучения основам ИИ [3; 5] были выделены и обоснованы компоненты методики обучения основам искусственного интеллекта и анализа данных в курсе информатики основного общего и среднего общего образования как преемственных образовательных уровней.

**Структура и компоненты методики обучения основам ИИ и анализа данных.** Разработанная методика вариативного обучения основам искусственного интеллекта и анализа данных в курсе информатики основного общего и среднего общего образования состоит из следующих компонентов:

- *интегративного методологического подхода* (основа для выбора концепции и реализации методики);
- *целевого компонента* (интегративная деятельностная основа содержания обучения и планируемых образовательных результатов);
- *содержательного компонента* (инвариантная и вариативная составляющая);
- *процессуального компонента* (современные методы, средства и формы обучения, новые образовательные технологии);
- *системы оценивания образовательных результатов* (в соответствии с новыми подходами обновленного ФГОС ОО).

Структура и состав методики вариативного обучения основам ИИ и анализа данных представлена на рис. 1.

Интегративный методологический подход в качестве концептуальной основы методики вариативного обучения ИИ позволит оперативно корректировать компоненты методики, ориентируясь на изменения технологических и образовательных трендов в рамках действия одного поколения ФГОС ОО. Целевой компонент учитывает образовательные запросы обучающихся, кадровые и цифровые ресурсы организации. Позволяет вводить гибкие форматы оценива-

ния образовательных результатов на основе разработанных детализированных предметных результатов изучения вопросов ИИ и анализа данных.

В качестве содержательного компонента методики представлено содержание теоретических и практических модулей основ искусственного интеллекта для реализации вариативных образовательных траекторий для основного общего (базовый и углубленный уровни изучения информатики) и среднего общего образования (базовый и углубленный уровни изучения информатики) с учетом возможностей проектно-исследовательской и внеурочной деятельности. Авторами сделаны акценты на подготовку к тематическим олимпиадам по искусственному интеллекту, а также на реализацию учебно-исследовательских проектов по тематике искусственного интеллекта и анализа данных [1]. Организационный компонент методики максимально учитывает персональные запросы участников образовательных отношений.



Рис. 1. Схема методики вариативного обучения основам ИИ и анализа данных

Для каждого уровня образования и уровня изучения информатики разработаны детализированные предметные и метапредметные результаты изучения тематики искусственного интеллекта и анализа данных. Для пошаговой диагностики продвижения к предметным и метапредметным результатам разработаны оценочные материалы:

- формирующего оценивания усвоения материала (могут использоваться в качестве стартовой диагностики в начале обучения);
- текущего оценивания продвижения по темам, относящимся к основам искусственного интеллекта;
- тематического (итогового по теме) оценивания, связанных с основами искусственного интеллекта и анализа данных;



- оценивания проектно-исследовательских работ обучающихся по тематике искусственного интеллекта.

Апробация разработанного тематического контента для основного общего и среднего общего образования проходила на занятиях, проводимых в стенах Института математики и информатики МПГУ с обучающимися московских школ, участвующих в проектах «ИТ-вертикаль» и «ИТ-класс».

**Обязательная и вариативная часть учебного плана при изучении основ ИИ на разных уровнях изучения информатики.** Обязательная часть (инвариант) осваивается в рамках основного содержания информатики с дополнением контента по искусственному интеллекту там, где это целесообразно и возможно сделать [8]. В виде дополнения к изучаемым темам приводятся примеры из жизни и профессиональных сфер деятельности, при этом используются новые понятия по тематике ИИ, а также выполняются небольшие практические упражнения на освоение повседневных интеллектуальных сервисов. Вариативная часть учебного плана (формируемая участниками образовательных отношений) при изучении вопросов искусственного интеллекта в курсе информатики представлена традиционно обязательной проектной деятельностью и всевозможными дополнительными активностями (см. рис. 2).

Представленный состав обязательной и вариативной частей учебного плана реализуется как в основном общем, так и в среднем общем образовании независимо от выбранного профиля обучения (кроме технологического).

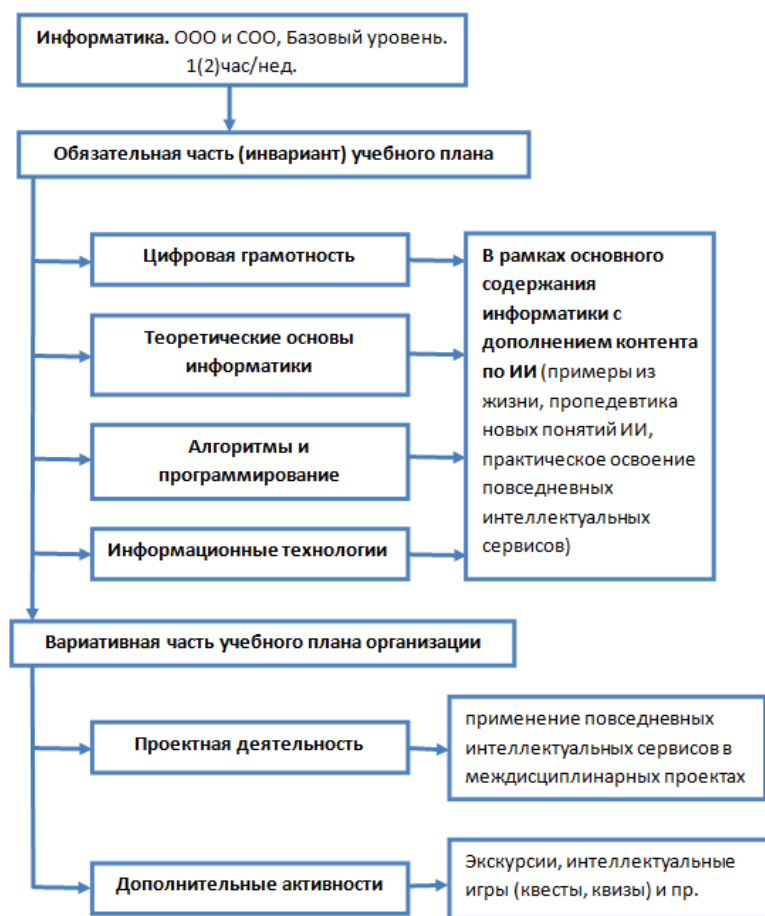


Рис. 2. Состав обязательной и вариативной частей учебного плана при изучении ИИ на базовом уровне

Для углубленного изучения информатики в общем образовании несколько более объемным будет контент для обязательной составляющей в рамках тематических разделов информатики и более разнообразной вариативная часть, его содержательная и деятельностная составляющие [4]. Предполагается, что в большинстве своем обучающиеся продолжают изучение информатики в старшей школе на углубленном уровне в технологическом профиле или предпрофессиональном классе. Вариант перехода с углубленного уровня основной школы на базовый уровень старшей школы учтен выше при формировании траекторий базового уровня изучения информатики.

В рамках основного содержания информатики с дополнением контента по ИИ на углубленном уровне приводятся примеры использования ИИ в профессиях, изучаются новые понятия ИИ и их взаимосвязь, рассматривается история возникновения и развития различных направлений ИИ. Большое внимание уделяется практическому освоению и осознанному применению повседневных интеллектуальных сервисов, а также решению задач ИИ и анализу больших данных с привлечением свободных дата-сетов. Схематично состав и взаимосвязи частей можно представить в виде рис. 3.

Углубленный уровень изучения информатики предполагает значимо разнообразную вариативную часть учебного плана (формируемая участниками образовательных отношений), поскольку тематика ИИ выходит на внешний контроль, т.е. представлена в предметных и метапредметных результатах освоения основной образовательной программы СОО. Проектная деятельность помимо применения повседневных интеллектуальных сервисов в междисциплинарных проектах ориентирована и на учебные исследования по тематике ИИ для увлеченных обучающихся, которые при этом существенно повысят навыки программирования вплоть до создания интеллектуальных продуктов.

В популярных инженерных классах старшеклассники переходят на интеллектуальную робототехнику. Прототипы продуктов, созданных на занятиях, позволяют принимать участие в конкурсах и соревнованиях, влияют на профессиональн

У учащихся также пользуются популярностью олимпиады школьников по искусственному интеллекту, как альтернативная форма поступления в вуз, соответственно требующие специальной подготовки к таким соревнованиям [1]. Образовательная организация может предложить курсы для подготовки к олимпиадам по ИИ, начиная с основной школы, где предусмотрено расширенное изучение Python с включением специальных библиотек для решения задач ИИ, анализа данных

ое самоопределение выпускников. Увлеченные обучающиеся не оставляют без внимания любые дополнительные активности по современной тематике.

**Заключение.** В результате исследования предложена структура и состав методики обучения основам ИИ и анализа данных в общеобразовательном курсе информатики, которая позволяет построить различные варианты образовательных программ, учитывающих переходы обучающихся с основного общего образования в среднее общее и спроектировать необходимое количество траекторий обучения в соответствии с персональными запросами участников образо-

вательных отношений, рационально использовать компоненты информационной образовательной среды организации при реализации основных образовательных программ общего образования.



Рис. 3. Состав обязательной и вариативной частей учебного плана при изучении ИИ в курсе информатики на углубленном уровне

## Библиографический список

1. Григорьев С. Г., Калинин И. А., Самылкина Н. Н. Система заданий для первой всероссийской олимпиады школьников по искусственному интеллекту. *Информатика и образование*. 2022;37(3):12–20. DOI: 10.32517/0234-0453-2022-37-3-12-20
2. Искусственный интеллект: 10-11 классы: учебное пособие/И.А.Калинин, Н.Н.Самылкина, А.А.Салахова. – Москва: Просвещение, 2023. – 144 с.ил. – (Профильная школа). URL: <https://shop.prosv.ru/iskusstvennyj-intellekt--10-11-klassy21811>. (Дата обращения: 17.08.2024 г.)
3. Левченко И.В., Садыкова А.Р., Меренкова П.А. Модель вариативного обучения учащихся основной школы в области искусственного интеллекта. *Информатика и образование*. 2024;39(2):16–24. <https://doi.org/10.32517/0234-0453-2024-39-2-16-24>
4. Приказ Министерства просвещения Российской Федерации от 12.08.2022 № 732 "О внесении изменений в федеральный государственный образовательный стандарт среднего общего образования, утвержденный приказом Министерства образования и науки Российской Федерации от 17 мая 2012 г. № 413" (Зарегистрирован 12.09.2022 № 70034): URL: <http://publication.pravo.gov.ru/Document/View/0001202209120008>. (Дата обращения: 17.08.2024 г.)
5. Самылкина Н. Н., Салахова А. А. Обучение основам искусственного интеллекта и анализа данных в курсе информатики на уровне среднего общего образования: монография. М.; МПГУ; 2022. 228 с. EDN: BASMCW. DOI: 10.31862/9785426310643.
6. Самылкина Н. Н. Организация углубленного обучения информатике на основе интегративного подхода: монография /Н.Н. Самылкина. Москва: МПГУ, 2020. 346 с.
7. Ткач Т. В. Машинное обучение и обработка больших данных в условиях современной школы. *Информатика в школе*. 2020;(7(160)):25-29. EDN: JETIPH. DOI: 10.32517/2221-1993-2020-19-7-25-29.
8. Федеральная рабочая программа основного общего образования (базовый уровень) (для 7-9 классов образовательных организаций). URL: [https://edsoo.ru/wp-content/uploads/2023/08/15\\_ФРП-Информатика-7-9-классы\\_база.pdf?ysclid=lsybid3lci419826100](https://edsoo.ru/wp-content/uploads/2023/08/15_ФРП-Информатика-7-9-классы_база.pdf?ysclid=lsybid3lci419826100) (Дата обращения 22.08.2024).
9. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
10. Israel-Fishelson R., Moon P. F., Tabak R., Weintrop D. Preparing students to meet their data: an evaluation of K-12 data science tools. *Behaviour & Information Technology*. Taylor&Francis; 2023:1–20. DOI: 10.1080/0144929X.2023.2295956.
11. Sang J. L., Kyungbin K., A systematic review of AI education in K-12 classrooms from 2018 to 2023. Topics, strategies, and learning outcomes. «Computers and Education: Artificial Intelligence». 6:2024. DOI: 10.1016/j.caeai.2024.100211

## VARIATIVE TEACHING OF THE BASICS OF ARTIFICIAL INTELLIGENCE IN THE SCHOOL COURSE OF COMPUTER SCIENCE

*Samylkina Nadezhda Nikolayevna*

Moscow Pedagogical State University,  
1, Malaya Pirogovskaya St., Moscow, 614068, Russia.  
[nsamylkina@yandex.ru](mailto:nsamylkina@yandex.ru)

The article presents the results of the research devoted to the development of a methodology of variant teaching of the basics of artificial intelligence (AI) and data analysis in the course of computer science of basic general and secondary general education taking into account extracurricular and project-research activities of students in accordance with the requirements of the updated Federal State Standard of Education and Science on the basis of the integrative methodological approach.

**Keywords:** artificial intelligence, data analysis, variable learning, integrative approach, updated FSES of general education, extracurricular activities, project activities.

## РАЗВИТИЕ ИИ-ТЕХНОЛОГИЙ В ОБРАЗОВАНИИ: ОБЗОР СОВРЕМЕННЫХ ИНСТРУМЕНТОВ И ИХ ПРИМЕНЕНИЕ

*Лелюх Алена Борисовна*

Московский педагогический государственный университет,  
119435, Россия, Москва, ул. Малая Пироговская, д. 1, стр. 1  
leluhalena@yandex.ru

Развитие ИИ открывает новые горизонты в образовании, предлагая инновационные решения для повышения качества обучения. В статье анализируются ключевые ИИ-инструменты, их функции, преимущества и вызовы. Рассматривается их влияние на решение проблем образования и развитие учебного процесса.

**Ключевые слова:** искусственный интеллект, образование, ИИ-инструменты, обучение, преподавание, образовательные технологии, адаптивное обучение.

**Введение.** Современные образовательные системы сталкиваются с рядом вызовов, включая необходимость персонализированного подхода к обучению [8], высокую нагрузку на преподавателей [9], потребность в инновационных методах оценки знаний и создании учебных материалов [4]. Цель статьи – предоставить обзор современных ИИ-инструментов, используемых в образовательной сфере, проанализировать их функциональные возможности и оценить их влияние на образовательный процесс.

Рассмотрим эти вызовы более подробно:

1. *Персонализированный подход к обучению.* В условиях разнообразия учеников с различными уровнями подготовки, стилями обучения и индивидуальными потребностями традиционные методы преподавания часто оказываются неэффективными. Персонализированный подход включает адаптацию образовательного процесса под конкретного ученика, что включает индивидуальные учебные планы, персонализированные задания и адаптивные технологии. Например, такой инструмент, как AI Tutor предоставляет возможность создания индивидуальных учебных программ и адаптацию материала в зависимости от потребностей и уровня подготовки учащегося. Инструмент может анализировать успеваемость и прогресс, чтобы предложить более целенаправленные ресурсы и задания [6]. Такие решения, как Cugipod [11] и Magic School [7] помогают создавать интерактивные уроки и адаптивные курсы, что также способствует более персонализированному обучению [1].

2. *Высокая нагрузка на преподавателей.* Преподаватели часто сталкиваются с перегрузкой из-за большого количества учебных заданий, проверки работ и взаимодействия с учениками. Эффективное управление классом, подготовка материалов и проведение оценивания требуют значительных временных и эмоциональных затрат. Для уменьшения нагрузки на преподавателей суще-

ствуют инструменты, которые автоматизируют рутинные процессы. Например, Gradescope [10] и ClassPoint AI позволяют автоматизировать оценивание заданий и создание интерактивных презентаций, тем самым сокращая время, затрачиваемое на эти задачи. ChatGPT и Grammarly предоставляют помощь в написании и проверке текстов, что может значительно упростить работу преподавателей при подготовке учебных материалов и коррекции работ студентов.

3. *Потребность в инновационных методах оценки знаний.* Традиционные методы, такие как письменные экзамены и тесты, не всегда отражают истинные способности и знания учащихся. Современные образовательные системы требуют гибких и точных методов оценки, учитывающих теоретические знания, практические навыки, критическое мышление и творческий подход. Индивидуальные потребности учащихся требуют гибких методов оценки знаний. Такой инструмент, как Quizizz предлагает создание интерактивных тестов и викторин, что позволяет оценивать не только теоретические знания, но и практические навыки. Gradescope и AI Tutor могут автоматически анализировать и оценивать выполнение заданий, что улучшает точность и скорость оценки, а также позволяет преподавателям сосредоточиться на более сложных аспектах обучения.

4. *Создание учебных материалов.* Разработка качественных учебных материалов, соответствующих современным требованиям и интересам учеников, представляет собой сложную задачу. Учебные материалы должны быть актуальными, доступными и способствовать активному вовлечению учащихся в учебный процесс. Создание актуальных и вовлекающих учебных материалов может быть облегченным благодаря инструментам, таким как Canva и Adobe Firefly, которые позволяют создавать графику и визуальные материалы с помощью ИИ. ChatPDF помогает в подготовке презентаций и взаимодействии с PDF-документами, что может значительно упростить работу по созданию и обновлению учебных ресурсов [2].

Таким образом инновационные решения и технологии, способны существенно улучшить образовательный процесс и сделать его более эффективным и адаптивным к современным требованиям. Таблица содержит перечень популярных ИИ-инструментов, применяемых в образовании. Отбор инструментов для анализа осуществлялся по следующим критериям:

- *актуальность* – рассматривались решения, которые на данный момент являются современными и активно применяются в образовательных целях;
- *функциональные характеристики* – способность удовлетворять потребности каждого ученика, автоматизировать рутинные процессы, наличие инновационных методов оценки, таких как автоматизированные тесты, проектные и интерактивные задания, которые позволяют получить более полную картину успеваемости учащихся.
- *рейтинги и статистика использования*, комментарии и обзоры пользователей.

## Обзор современных ИИ-технологий в образовании

ИНСТРУМЕНТ	ОПИСАНИЕ	ОСНОВНЫЕ ФУНКЦИИ
<b>ChatGPT</b> <a href="https://chat.openai.com">https://chat.openai.com</a>	Модель ИИ от OpenAI для общения и генерации текстов.	- написание и проверка текстов; - поиск информации; - решение задач; - перевод текстов; - сжатие материалов; - подготовка планов
<b>Gemini</b> <a href="https://gemini.google.com">https://gemini.google.com</a>	Продукт компании Google, доступный как десктопная версия и на мобильных устройствах.	- написание и проверка текстов; - перевод; - изучение языков; - составление тестов; - решение задач.
<b>MathGPT</b> <a href="https://www.mathgpt.com">https://www.mathgpt.com</a>	Инновационный ИИ для решения математических задач разного уровня сложности.	- решение математических задач; - генерация задач и формул; - поддержка текстовых запросов и картинок.
<b>Character.AI</b> <a href="https://character.ai">https://character.ai</a>	ИИ-продукт для общения с различными персонажами.	- общение с персонажами; - развитие навыков письма; - практика языков
<b>DeepL</b> <a href="https://www.deepl.com">https://www.deepl.com</a>	Глобальный инструмент для перевода текстов с высокой точностью.	- перевод текстов; - улучшение материалов (правки, рекомендации).
<b>Perplexity</b> <a href="https://www.perplexity.ai">https://www.perplexity.ai</a>	ИИ-поисковик для облегчения работы с информацией.	- поиск информации; - ответы на вопросы; - написание текстов; - перевод
<b>YandexGPT</b> <a href="https://ya.ru/ai/gpt-3">https://ya.ru/ai/gpt-3</a>	ИИ-продукт от Яндекс для работы с текстами и задачами.	- написание и проверка текстов; - поиск ответов; - решение задач; - формирование списков литературы.
<b>QuillBot</b> <a href="https://quillbot.com">https://quillbot.com</a>	Инструмент для перефразирования и проверки грамматики.	- перефразирование; - сокращение текстов; - улучшение стиля письма.
<b>AI Tutor</b> <a href="https://www.aitutorpro.ca/">https://www.aitutorpro.ca/</a>	Виртуальный репетитор для различных предметов.	- персонализированное обучение; - объяснение концепций; - помощь с задачами.
<b>Otter.ai</b> <a href="https://otter.ai/">https://otter.ai/</a>	Программа для автоматической транскрипции аудио.	- транскрипция в реальном времени; - создание заметок по аудиофайлам.
<b>Canva</b> <a href="https://www.canva.com">https://www.canva.com</a>	Платформа для создания графики с помощью встроенных ИИ-инструментов.	- генерация изображений и дизайнов; - создание презентаций и материалов.
<b>Gradescope</b> <a href="https://www.gradescope.com/">https://www.gradescope.com/</a>	Инструмент для автоматизации оценки заданий с использованием ИИ.	- оценивание с помощью ИИ; - поддержка бумажных и онлайн-заданий.
<b>Magic School</b> <a href="https://www.magicschool.com">https://www.magicschool.com</a>	Образовательная платформа с применением ИИ для создания учебных материалов и курсов.	- создание учебных материалов; - поддержка адаптивного обучения.

ИНСТРУМЕНТ	ОПИСАНИЕ	ОСНОВНЫЕ ФУНКЦИИ
<b>Course Hero</b> <a href="https://www.coursehero.com">https://www.coursehero.com</a>	Платформа для улучшения образовательного процесса с использованием ИИ данных.	персонализированное обучение; помощь в выполнении домашних заданий на базе ИИ.
<b>Duolingo</b> <a href="https://www.duolingo.com">https://www.duolingo.com</a>	Приложение для изучения языков с помощью ИИ, адаптированное под студента.	персонализированное обучение языкам; интерактивные задания и упражнения.
<b>Quizizz</b> <a href="https://quizizz.com/">https://quizizz.com/</a>	Платформа для создания интерактивных тестов и викторин с применением ИИ.	создание тестов; оценка и анализ результатов учащихся.
<b>Fireflies.AI Corp.</b> <a href="https://fireflies.ai">https://fireflies.ai</a>	Платформа для записи, анализа и транскрипции совещаний и уроков с помощью ИИ.	автоматическая запись и транскрипция; анализ встреч и уроков.
<b>Adobe Firefly</b> <a href="https://www.adobe.com">https://www.adobe.com</a>	Инструмент для генерации изображений и видео на базе ИИ.	создание графики и анимации; улучшение визуальных материалов.
<b>ChatPDF</b> <a href="https://chatpdf.com/">https://chatpdf.com/</a>	Приложение для взаимодействия с PDF-документами с помощью ИИ.	быстрый анализ PDF-документов; извлечение и структурирование информации.
<b>ClassPoint AI</b> <a href="https://www.classpoint.io/">https://www.classpoint.io/</a>	Инструмент ИИ для создания интерактивных презентаций и заданий в PowerPoint.	создание интерактивных презентаций; оценка вовлеченности учащихся.

Для эффективного внедрения ИИ в образовательные процессы следует также учитывать несколько ключевых факторов:

1. *Обучение преподавателей.* Успешная работа с ИИ требует от преподавателей определенной подготовки. Им нужно не только осваивать функциональные возможности инструментов, но и уметь адаптировать их к потребностям учеников.

2. *Адаптация инструментов под учебные программы.* Инструменты ИИ должны соответствовать специфике преподаваемых предметов и уровню подготовки учащихся [3]. Например, MathGPT идеально подходит для решения математических задач, а Character.AI – для гуманитарных дисциплин.

3. *Интеграция с системами управления обучением (LMS).* Для повышения эффективности использования ИИ важно интегрировать его с уже существующими системами управления обучением [5], такими как Moodle, Microsoft Teams или Blackboard.

4. *Оценка эффективности использования ИИ.* Постоянный мониторинг и оценка влияния ИИ на образовательный процесс помогут выявить как положительные, так и отрицательные аспекты, например, зависимость от технологий или возможные ошибки в оценивании.



5. *Этика и безопасность данных.* Использование ИИ должно сопровождаться строгими мерами по защите персональных данных учеников, что важно для обеспечения конфиденциальности и этичности.

Перспективы использования ИИ в образовании на текущем этапе использования ИИ представляются следующими:

1. *Индивидуализированное обучение на новом уровне.* Благодаря постоянному развитию адаптивных технологий, ИИ сможет предлагать более точные и персонализированные учебные программы для каждого ученика. Это не только повысит успеваемость, но и снизит уровень стресса у учеников, позволяя им учиться в удобном темпе.

2. *Развитие ИИ-ассистентов для преподавателей.* В будущем ИИ-инструменты смогут не только помогать с рутинными задачами, но и предоставлять преподавателям аналитику по прогрессу каждого ученика. Это позволит преподавателям принимать более обоснованные решения при выборе стратегии обучения.

3. *Геймификация и интерактивное обучение.* ИИ продолжит совершенствование интерактивных платформ, таких как Quizlet и Curipod, предлагая более захватывающие и игровые форматы обучения. Это может повысить вовлеченность учеников и сделать учебный процесс более увлекательным и эффективным.

4. *Автоматизация создания учебных материалов.* В будущем ИИ сможет самостоятельно разрабатывать учебные материалы, основываясь на данных об учебных предпочтениях учащихся и их уровнях знаний. Это существенно сократит время на подготовку к занятиям и повысит качество материалов.

5. *Международное сотрудничество.* ИИ-инструменты, такие как DeepL и Duolingo, уже сейчас помогают в изучении иностранных языков. В перспективе они смогут играть более активную роль в создании международных образовательных проектов и программ, предоставляя доступ к обучению на различных языках и в различных культурных контекстах.

6. *Инклюзивное образование.* ИИ-технологии имеют потенциал сделать образование более инклюзивным, предоставляя возможности для адаптации учебных материалов для учеников с особыми потребностями. Например, инструменты для транскрипции аудио, такие как Otter.ai, могут помочь ученикам с нарушениями слуха, а адаптивные платформы – предоставить учебные планы для учеников с различными когнитивными особенностями.

**Заключение.** Перспективы использования ИИ в образовании открывают огромные возможности для развития персонализированного и инклюзивного подхода к обучению. Однако успешное внедрение технологий требует не только грамотного использования существующих решений, но и постоянного совершенствования учебных программ и подходов к преподаванию. Важно помнить, что ИИ должен оставаться вспомогательным инструментом, а не заменой для живого взаимодействия и педагогической интуиции преподавателя.

## Библиографический список

1. Котлярова И.О. Технологии искусственного интеллекта в образовании // Вестник ЮУрГУ. Серия: Образование. Педагогические науки. 2022. №3. [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/tehnologii-iskusstvennogo-intellekta-v-obrazovanii-2> (дата обращения: 17.08.2024).
2. Лебедева Т.М., Анпилова Л.М. Польза нейросети для эффективного обучения современного школьника // Форум молодых ученых. 2024. №8 (96). [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/the-use-of-a-neural-network-for-effective-teaching-a-modern-student> (дата обращения: 10.09.2024).
3. Родионов О.В., Тамп Н.В. Технологии искусственного интеллекта в образовании // Воздушно-космические силы. Теория и практика. 2022. №22. [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/tehnologii-iskusstvennogo-intellekta-v-obrazovanii-1> (дата обращения: 10.09.2024).
4. Соловова Н. В. Методическая компетентность преподавателя вуза // Вестник Балтийского федерального университета им. И. Канта. Серия: Филология, педагогика, психология. 2010. №5. [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/metodicheskaya-kompetentnost-prepodavatelya-vuza>
5. Ущeko А.В. Искусственный интеллект в образовании. Применение искусственного интеллекта для обеспечения адаптивности образования // Вестник науки. 2023. №6 (63). [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-v-obrazovanii-primeneniye-iskusstvennogo-intellekta-dlya-obespecheniya-adaptivnosti-obrazovaniya> (дата обращения: 17.09.2024).
6. Baillifard, Ambroise, et al. "Effective learning with a personal AI tutor: A case study." *Education and Information Technologies* (2024): 1-16. [Электронный ресурс]. Режим доступа: [https://www.researchgate.net/publication/324162661\\_Personalisation\\_in\\_educational\\_technology\\_the\\_absence\\_of\\_underlying\\_pedagogies](https://www.researchgate.net/publication/324162661_Personalisation_in_educational_technology_the_absence_of_underlying_pedagogies)
7. Hatim Muhammad Mustafa, Somaya Shokry Mahmoud , Hayah Mohamed Abouelnaga , Mohammed Tayfour , Ahmed Baz Mohamed Metwally , Saleh M. Shehata. (2024). The Effect Of The Training Of Using Magic School AI On Self-Efficacy In Teaching And Information Overload Among Arabic Teachers. *Migration Letters*, 21(S9), 1361–1370. [Электронный ресурс]. Режим доступа: <https://migrationletters.com/index.php/ml/article/view/10368>
8. Zdravkova, K. Personalized Education for Sustainable Development. *Sustainability* 2023, 15, 6901. [Электронный ресурс]. Режим доступа: <https://doi.org/10.3390/su15086901>
9. Lijana, Navickienė., Eglė, Stasiūnaitienė., Ilona, Kupčikienė., Donatas, Misiūnas. (2019). Stressors in teacher's work. *Public Health*, 28(6), 29-34. [Электронный ресурс]. Режим доступа: <https://doi.org/10.5200/sm-hs.2018.067>
10. Singh A., Karayev S., Gutowski K. Abbeel P. Gradescope: A Fast, Flexible, and Fair System for Scalable Assessment of Handwritten Work. In *Proceedings of the Fourth (2017) ACM Conference on Learning @ Scale (L@S '17)*. Association for Computing Machinery, New York, NY, USA, 81–88. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1145/3051457.3051466>
11. Sbardella Talia; Montanucci Giorgia. Curipod: A Tool for Creating and Delivering AI-enhanced lessons." *LT* (2024), 33-35 [Электронный ресурс]. Режим доступа: <https://ricerca.unistrapg.it/handle/20.500.12071/39472>

## DEVELOPMENT OF AI TECHNOLOGY IN EDUCATION: OVERVIEW OF MODERN TOOLS AND THEIR APPLICATIONS

*Lelyukh Alena Borisovna*

Moscow Pedagogical State University,  
119435, Russia, Moscow, st. Malaya Pirogovskaya, 1, building 1  
[leluhalena@yandex.ru](mailto:leluhalena@yandex.ru)

The development of AI opens up new horizons in education, offering innovative solutions to improve the quality of learning. The article analyzes key AI tools, their functions, advantages and challenges. Their influence on solving educational problems and developing the educational process is considered.

**Keywords:** artificial intelligence, education, AI tools, learning, teaching, educational technologies, adaptive learning

## ИССЛЕДОВАНИЕ АКТУАЛЬНОСТИ ИСПОЛЬЗОВАНИЯ ИИ В ОБРАЗОВАТЕЛЬНОМ ПРОЦЕССЕ В ШКОЛЕ

***Кобзев Иван Дмитриевич***

Институт Бизнеса БГУ,  
220004, Республика Беларусь, г. Минск, ул. Обойная, 7  
ivan.d.kobzev@gmail.com

***Мочалова Вера Кирилловна***

Институт Бизнеса БГУ,  
220004, Республика Беларусь, г. Минск, ул. Обойная, 7  
vera-m-06@mail.ru  
Научный руководитель

***Лесниченко-Роговская Мария Владимировна***

Институт Бизнеса БГУ,  
220004, Республика Беларусь, г. Минск, ул. Обойная, 7  
mari\_lesnichenko@mail.ru

Статья посвящена исследованию использования искусственного интеллекта (ИИ) в образовательном процессе и его влиянию на развитие современной педагогики. Рассматриваются основные направления использования ИИ в обучении, включая персонализацию образовательного процесса, создание интерактивных учебных материалов, поддержку преподавателей и автоматизацию оценки знаний. В работе приводятся примеры успешной интеграции ИИ-решений, таких как AI-репетиторы и платформы дистанционного обучения.

**Ключевые слова:** искусственный интеллект, ИИ в образовании.

**Введение.** На протяжении уже нескольких лет искусственный интеллект (ИИ) является неотъемлемой частью нашей жизни, оказывая влияния на различные сферы жизнедеятельности общества, например, медицину, финансы, экономику и, конечно, образование. С каждым днем популярность ИИ только растет, улучшая качество и доступность знаний [1]. В условиях стремительного развития технологий и изменения потребностей общества, образование сталкивается с необходимостью адаптаций.

Рассмотрим преимущества и недостатки, которые дает использование ИИ в образовательном процессе. К плюсам можно отнести: экономию времени для учителей (т. е. автоматизацию рутинных процессов, что значительно экономит ресурсы учителя); использование ИИ для создания учебных материалов, которые будут направлены на индивидуальные потребности и уровень знаний каждого ученика [2]. Также нейросети способствуют тому, чтобы уроки стали более интерактивными и интересными, вследствие чего занятия становятся более эффективными. Кроме того, ИИ заметно упрощает процесс удаленного обучения, повышая качество образования с использованием данного формата.

Несмотря на все преимущества, использование ИИ в образовании может привести и к ряду серьезных проблем. Это включает в себя снижение уровня социализации и уменьшение взаимодействия учеников с учителями. Также воз-

никают трудности с формированием критического мышления: из-за широкого распространения нейросетей у студентов могут возникнуть проблемы с принятием важных решений, поскольку многие задачи они смогут решать только с помощью ИИ [3].

В статье рассматривается влияние и значение искусственного интеллекта на образовательный процесс, опираясь на практические примеры его применения, а также на собственный опыт работы с ИИ. Эти примеры демонстрируют, как ИИ может трансформировать подходы к обучению, способствуя развитию критического мышления, улучшению успеваемости и созданию более интерактивной образовательной среды.

**Основная часть.** Развитие информационных технологий вывело искусственный интеллект на новый уровень, где он может широко применяться в образовании. ИИ в обучении раскрывает потенциал учащихся и преподавателей и повышает эффективность в работе.

Рассмотрим теоретические способы применения ИИ в образовательном процессе. Так, в недавней исследовательской работе Фань Оуян и Пэнчэн Цзяо из Чжэцзянского университета выделили три парадигмы искусственного интеллекта в образовании.

1) **Парадигма первая:** учащийся как получатель. ИИ используется для представления моделей знаний и прямого когнитивного обучения, в то время как учащиеся являются получателями услуг ИИ.

2) **Парадигма вторая:** учащийся как участник. ИИ используется для поддержки обучения, в то время как учащиеся работают в сотрудничестве с ИИ.

3) **Парадигма третья:** ученик как лидер. ИИ используется для расширения возможностей обучения, в то время как учащиеся принимают участие в обучении.

**Исследования в Гане.** В последние годы искусственный интеллект (ИИ) находит всё большее применение в образовательной сфере, предлагая новые возможности для улучшения учебного процесса. Одним из ярких примеров является исследование, проведенное в Гане, которое продемонстрировало положительное влияние AI-репетитора на успеваемость учащихся в математике.

В рамках эксперимента почти тысяча учеников 3-9 классов из 11 различных школ в Гане в течение восьми месяцев занимались с AI-ботом по имени Rori, доступным через WhatsApp. Участники эксперимента занимались математикой два раза в неделю по 30 минут, что позволило интегрировать занятия в расписание внеурочной деятельности. В это время ученики также имели доступ к преподавателю, что создавало условия для дополнительной поддержки.

AI-бот Rori использовал метод Сократовского диалога, предлагая учащимся решать задачи, анализировать их ошибки и не выдавая ответ сразу, что способствовало более глубокому пониманию материала. Оценка результатов проводилась с помощью теста из 35 вопросов. В начале эксперимента дети в обеих группах решали в среднем 20.2 задания, однако по окончании эксперимента контрольная группа показала результат в 22.2 задания, в то время как студенты с AI-ассистентом достигли 25.4 задания. Эта разница оказалась статистически значимой.

Авторы исследования отмечают, что стоимость использования такого ассистента составляет всего \$10 в год на одного ученика, что делает его доступным для образовательных учреждений, особенно в странах с ограниченными ресурсами. Важно отметить, что, несмотря на положительные результаты, исследование подвергалось критике. Некоторые эксперты указывают на то, что ученики из тестовой группы тратили на занятия с ботом на час в неделю больше времени, что могло также повлиять на результаты. Тем не менее, предполагается, что основным фактором успеха является именно использование ИИ, который предоставляет индивидуализированную помощь и поддерживает учащихся в процессе обучения.

Таким образом, результаты данного исследования подчеркивают потенциал использования искусственного интеллекта в образовании, особенно в контексте развивающихся стран, где доступ к качественному образованию может быть ограничен. AI-ассистенты могут стать важным инструментом для повышения успеваемости и обеспечения более равного доступа к образовательным ресурсам [4].

**Практическая часть исследования.** Авторами была разработана анкета, включающая вопросы, касающиеся осведомленности школьников о нейросетях, их восприятия влияния ИИ на образование. Основной целью исследования является получение эмпирических данных, на основе которых можно будет сделать выводы об ознакомленности и интересах школьников участвовать в образовательной деятельности с применением искусственного интеллекта.

Анкета предназначена для учащихся средней школы в возрасте от 12 до 14 лет. Мы распространили ее среди школьников различных учебных заведений с помощью как Google-forms. Анализ результатов анкеты позволило нам выявить ключевые тенденции восприятия учащимися ИИ и сделать выводы об актуальности применения данного инструмента.

Результаты опроса среди 20 учащихся средней школы показали, что большинство школьников (70%) знают, что такое искусственный интеллект (ИИ), и 70% в той или иной степени используют его в учебе. Основное применение ИИ – это поиск информации по учебным темам (60%). Однако 30% опрошенных никогда не использовали ИИ для учебы. При этом мнения о возможности замены учителей ИИ разделились поровну, что подчеркивает важность человеческого фактора в образовательном процессе.

Вопрос о необходимости обучения работе с ИИ вызвал разногласия: 50% считают, что это полезно, но не обязательно, а по 25% респондентов считают это либо важным, либо ненужным.

Несмотря на высокую осведомленность и использование ИИ, остается необходимость дальнейшего внедрения и обучения школьников навыкам работы с ИИ, чтобы они могли эффективно использовать его потенциал в учебе и будущей профессиональной деятельности.

Исследование показало, что, несмотря на довольно высокую осведомленность учащихся об ИИ и его использовании в образовательных целях, существует необходимость более систематического обучения школьников работе с ИИ.

**Заключение.** Искусственный интеллект обладает большим потенциалом в образовательном процессе, особенно в выполнении рутинных задач и помощи преподавателю. Однако, несмотря на все его преимущества, ИИ не способен полностью заменить учителя. Преподаватель играет ключевую роль в социализации учеников и обучении их навыкам общения, чего искусственный интеллект обеспечить не может. Учитель не только передает знания, но и помогает детям строить человеческие взаимоотношения, что и остается незаменимой частью образовательного процесса.

Результаты исследования показали, что важно помочь учащимся лучше понять возможности ИИ и его применение в учебе, а также уменьшить их опасения относительно будущего, связанного с автоматизацией и искусственным интеллектом.

### **Библиографический список**

1. Trends.rbc.ru – Насколько популярен ИИ и все ли пользуются. [Электронный ресурс]. Режим доступа: <https://trends.rbc.ru/trends/industry/6679501b9a79475b7722d64a>
2. Postupai.com – Искусственный интеллект помогает или мешает учиться. [Электронный ресурс]. Режим доступа: <https://www.postupai.com/news/iskusstvennyi-intellekt>
3. Cyberleninka.ru – Искусственный интеллект в сфере образования: плюсы и минусы. [Электронный ресурс]. Режим доступа: <https://www.avito.ru/perm/nedvizhimost>
4. Arxiv.org – Эффективная и масштабируемая поддержка по математике: Данные о влиянии ИИ-репетитора на успеваемость по математике в Гане. [Электронный ресурс]. Режим доступа: <https://arxiv.org/abs/2402.09809>

## **STUDY OF THE RELEVANCE OF USING II IN THE EDUCATIONAL PROCESS AT SCHOOL**

***Kobzev Ivan Dmitrievich,***

Institute of Business BSU,  
220004, Republic of Belarus, Minsk, Oboynaya St., 7  
[ivan.d.kobzev@gmail.com](mailto:ivan.d.kobzev@gmail.com)

***Mochalova Vera Kirillovna***

Institute of Business BSU,  
220004, Republic of Belarus, Minsk, Oboynaya St., 7  
[vera-m-06@mail.ru](mailto:vera-m-06@mail.ru)

The article is devoted to the study of the role of artificial intelligence (AI) in the educational process and its impact on modern pedagogy. The main directions of AI use in education are considered, including personalization of the educational process, creation of interactive learning materials, teacher support and automation of knowledge assessment. The paper provides examples of successful integration of AI solutions such as AI tutors and distance learning platforms.

**Keywords:** artificial intelligence, AI in education.

## КОНЦЕПЦИЯ МОДЕЛИ ИНТЕГРАЦИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В БИЛИНГВАЛЬНЫЕ ПРОГРАММЫ ДЛЯ ДЕТЕЙ ДОШКОЛЬНОГО ВОЗРАСТА

***Садыкова Гульнара Василевна***

Казанский (Приволжский) федеральный университет,  
420008, Россия, г. Казань, ул. Кремлевская 18  
gsadykov@kpfu.ru

***Каюмова Альбина Рамилевна***

Казанский (Приволжский) федеральный университет,  
420008, Россия, г. Казань, ул. Кремлевская 18  
alb1980@yandex.ru

В статье представлена концепция модели интеграции технологий искусственного интеллекта в программы билингвального развития детей дошкольного возраста. Концепция основана на четырех положениях, учитывающих критически важную роль педагога, психофизические и когнитивные потребности ребенка, необходимость применения интегративного подхода и билингвальных технологий при развитии языковых навыков и компетенций в области искусственного интеллекта. Представленная концепция способствует пониманию траектории движения при разработке сценариев применения смарт-платформ в обучении детей 4-7 лет.

**Ключевые слова:** технологии искусственного интеллекта, дошкольное образования, билингвальное образование, английский язык как иностранный.

**Введение.** Вопрос использования технологий искусственного интеллекта (ИИ) в образовательные программы стал одним из наиболее актуальных и широко обсуждаемых в академическом сообществе в России и за рубежом. Разработка и внедрение в широкие массы генеративного ИИ в ноябре 2022 года способствовали популяризации смарт-технологий и экспериментам с их использованием педагогами нетехнических специальностей, в частности, языковедами. Благодаря возможностям генерации устных и письменных текстов, интеллектуальные системы стали использоваться как инструменты развития языковых навыков, в первую очередь компетенций в области иностранных языков. Недавние исследования свидетельствуют о значительном потенциале ИИ как средств развития как рецептивных языковых навыков (аудирования и чтения), так и продуктивных (говорения и письма). Эмпирические данные говорят о возможности успешного использования интеллектуальных систем для развития навыка различения и произнесения звуков, обогащения словарного запаса, овладения грамматическими средствами общения, усовершенствования беглости, логичности, когерентности устной и письменной речи, овладения стилистическими приемами и др. [1-3]. Более того, применение ИИ-платформ может способствовать созданию дружелюбной, увлекательной, интерактивной обу-

чающей среды, благоприятно влияющей на мотивацию изучающих иностранный (и/или родной/второй родной) язык.

Хотя потенциал ИИ технологий в языковом образовании уже получил освещение в научной литературе, в настоящее время можно говорить о наличии пробела в понимании того, насколько может быть эффективным и безопасным интеграция смарт-систем в дошкольное образование в целом и в языковое развитие детей в частности. Пока вопросы использования искусственного интеллекта как одного из средств обучения языку детей дошкольного возраста находятся в «фазе эмбриона» [4:356]. Вместе с тем опрос воспитателей, ранее проведенный авторами данной статьи [5], говорит о наличии значительного интереса к ИИ-технологиям среди тех, кто работает с детьми дошкольного возраста, но также свидетельствует об отсутствии понимания методики интеграции ИИ-технологий в существующие образовательные программы. Представленное исследование призвано обозначить концептуальные основы модели интеграции технологий искусственного интеллекта в языковые программы детей-дошкольников, изучающих иностранный (английский) язык.

**Методология исследования.** С января 2024 года научной группой Казанского федерального университета реализуется исследовательский проект, целью которого является создание и апробация модели интеграции технологий искусственного интеллекта в программы билингвального развития детей дошкольного возраста.

На начальном этапе был проведен опрос педагогов дошкольных образовательных организаций (N=132), позволивший обозначить современное состояние вопроса, а именно выявить отношение педагогов к ИИ, уровень ИИ-компетенций и степень использования интеллектуальных технологий в образовательном процессе.

На втором этапе были проведены два эксперимента, в котором приняли участие дети 4-6 лет (N=28), изучающие английский язык как иностранный в одном из частных полилингвальных детских садов. В апробации были привлечены две платформы, построенные на базе искусственного интеллекта: платформа *FusionBrain*, позволяющая создавать статичные изображения и короткие анимационные видео, и платформа *SUNOAI*, дающая возможность создать песню на основе текстового запроса. Источником данных стали видеозаписи занятий (два 5-и дневных модуля с каждой из платформ ИИ), языковые (лексические) тесты, проведенные на констатирующем и контрольном этапе, анкета педагога, дневник рефлексии с ежедневными записями педагога, постинтеграционное интервью с педагогом, документы образовательной организации (программа, сайт). Данные были подвергнуты количественному и качественному анализу.

Результаты первого и второго этапа исследования легли в основу концепции модель интеграции технологий искусственного интеллекта в программы билингвального развития детей дошкольного возраста.

**Результаты исследования.** Анализ ответов на вопросы опросника свидетельствует о положительном отношении педагогов к технологиям искусственного интеллекта, но также говорит об отсутствии компетенций в этой области и



низком уровне интеграции смарт-платформ в образовательный процесс. Немногочисленные попытки внедрения новых инструментов носят, как правило, экспериментальный и несистемный характер. Результаты опроса подробно изложены в статье авторов [5].

Эксперименты, проведенные на площадке полилингвального детского сада, говорят о наличии значительного потенциала, заложенного в ИИ-платформах, позволяющих создавать увлекательный и продуктивный сценарий развития языковых компетенций детей 4-6 лет. Констатирующий и контрольный срезы показали эффективность использования ИИ-платформ для расширения словарного запаса детей как в первом эксперименте с платформой FusionBrain (Рис.1), так и во втором эксперименте с SUNOAI (Рис.2). Детальный анализ результатов экспериментов представлен в статье авторов [6].




Рис. 1. Средний результат тестирования (группа Fusion Brain) (%)




Рис. 2. Средний результат тестирования (группа SunoAI) (%)

Опрос педагогов, апробация смарт-платформ *FusionBrain* и *SUNOAI*, а также опыт создания сценариев их интеграции в образовательную программу позволил сформулировать четыре положения (концептуальные доминанты), на основе которых должна базироваться модель интеграции технологий искусственного интеллекта в программы билингвального развития детей дошкольного возраста.

*Концептуальная доминанта №1:* Платформы, построенные на основе технологий искусственного интеллекта, являются *второстепенными* медиаторами знаний. Первостепенным медиатором знаний является педагог (воспитатель, учитель, родитель). Данное положение позволяет исключить негативное влияние технологий генеративного ИИ, связанное с непредсказуемостью ответа платформы на запрос и возможными искажениями действительности, что имело место быть при реализации экспериментальных сценариев [6]. Педагог также осуществляет контроль способа и продолжительности взаимодействия ребенка с технологией ИИ.

*Концептуальная доминанта №2:* Отбор технологий ИИ и сценарий их интеграции должен принимать во внимание *психофизическое развитие и когнитивные потребности* детей. Учитывая экспонентный рост смарт-систем и активное развитие рынка образовательных ИИ-платформ, становится принципиально важным осуществлять экспертную оценку их образовательного потенциала для конкретной целевой аудитории. Для детей дошкольного возраста могут быть использованы мультимодальные платформы, имеющие функции визуализации, озвучивания текста, понимания устной речи, голосового ответа, создания музыкального сопровождения, генерации несложных текстов. Также ИИ-платформы могут содержать элементы геймификации, построенные на образовательном контенте, соответствующем возрасту пользователя.

*Концептуальная доминанта №3:* Модель интеграции ИИ-технологий должна предусматривать как развитие языковых навыков, так и *компетенций в области искусственного интеллекта* в целом. Сценарий интеграции также может быть реализован в рамках *технологии предметно-языкового интегрированного обучения* (англ. Content and Language Integrated Learning, CLIL), при котором иностранный язык используется как средство для изучения другой дисциплины, например, окружающего мира, искусства или робототехники. Как показали эксперименты второго этапа, интеграция контента разных областей знаний в едином образовательном модуле является наиболее приемлемой для существующих программ дошкольных организаций. Вместе с тем, развитие ИИ-компетенций с раннего возраста способствует формированию цифровой грамотности, востребованной в современном обществе.

*Концептуальная доминанта №4:* Модель интеграции ИИ-технологий в программы развития иноязычной речи детей раннего возраста должна предусматривать 1) факт *параллельного развития* родной речи, 2) возможность *переключения кодов* (с русского на английский и наоборот) при взаимодействии с ИИ-технологией, педагогом и/или другими детьми. Эксперименты свидетельствуют о том, что билингвальный контекст взаимодействия «ребенок-ИИ-педагог» является оптимальным для создания комфортной и продуктивной среды обучения.

**Заключение.** Становясь неотъемлемой частью существования информационного общества, технологии ИИ прочно входят в жизнь современных людей, включая детей дошкольного возраста. Как и другие ставшие уже традиционными ИКТ, интеллектуальные системы могут стать помощниками педагогам только при условии их грамотного использования как образовательного инструмента. Разработка модели интеграции технологий искусственного интеллекта в программы билингвального развития детей дошкольного возраста – это шаг в сторону создания полноценной образовательной программы, направленной на всестороннее развитие ребенка, обучающегося в эпоху интеллектуальных образовательных систем.

**Финансирование.** Исследование выполнено за счет гранта Российского научного фонда №24-28-01129. Подробнее см.: <https://rscf.ru/project/24-28-01129/>

## Библиографический список

1. Ghoneim, N. M. M., & Elghotmy, H. E. A. Using an artificial intelligence based program to enhance primary stage pupils' EFL listening skills. *Al-Mağalla. Al-tarbawiyya* (Print). 2021, Vol. 83, pp. 1-324. Режим доступа: doi:10.21608/edusohag.2021.140694
2. Zhao, X. Leveraging Artificial intelligence (AI) technology for English Writing: Introducing Wordtune as a Digital writing assistant for EFL writers. 2022. *RELC Journal*. Vol. 54(3), pp. 890-894. Режим доступа: doi:10.1177/00336882221094089
3. Kang, H. Effects of Artificial Intelligence (AI) and Native Speaker Interlocutors on ESL Learners' Speaking Ability and Affective Aspects. 2022. *Multimedia-Assisted Language Learning*. Vol. 25(2), pp. 9-43.
4. Kewalramani, S., Palaiologou, I., Dardanou, M., Allen, K., & Phillipson, S. Using robotic toys in early childhood education to support children's social and emotional competencies. *Australasian Journal of Early Childhood*. 2021. Vol. 46(4), pp. 355-369. Режим доступа: doi:10.1177/18369391211056668
5. Sadykova, G., & Kayumova, A. Artificial Intelligence in Preschool Language Education: Are Educators Ready? Proceedings of the 13th International Conference on Smart Cities and Green ICT Systems – SMARTGREENS. [В печати].
6. Садыкова Г. В., Каюмова А. Р., Ибрагимова Д. И. Платформы генеративного искусственного интеллекта в языковых программах детей дошкольного возраста. [На рецензировании].

## THE CONCEPTUAL FOUNDATION OF A MODEL FOR INTEGRATION OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES INTO BILINGUAL PROGRAMS FOR PRESCHOOL CHILDREN

***Gulnara V. Sadykova***

Kazan (Volga Region) Federal University,  
18 Kremlevskaya St., Kazan, Russia, 420008  
gsadykov@kpfu.ru

***Albina R. Kayumova***

Kazan (Volga Region) Federal University,  
18 Kremlevskaya St., Kazan, Russia, 420008  
alb1980@yandex.ru

The article presents the conceptual foundation of a model for integration of artificial intelligence technologies into bilingual programs for preschool children. The conceptual foundation is based on four assumptions that take into account the critical role of the teacher, the psychophysical and cognitive needs of the child, the need to use an integrative approach and bilingual technologies in the development of language skills and competencies in the field of artificial intelligence. The concept may serve as a guidepath when designing scenarios for the application of smart platforms in teaching children aged 4-7.

**Keywords:** artificial intelligence technologies, preschool education, bilingual education, English as a foreign language.

## ПРОЕКТИРОВАНИЕ И РЕАЛИЗАЦИЯ ВНЕУРОЧНЫХ МЕРОПРИЯТИЙ ПО ИСКУССТВЕННОМУ ИНТЕЛЛЕКТУ ДЛЯ ОБУЧАЮЩИХСЯ 10-11 КЛАССОВ

*Худякова Анна Владимировна*

Пермский государственный гуманитарно-педагогический университет  
614068, г. Пермь, ул. Сибирская, 24  
ahudyakova@pspu.ru

Представлено описание внеурочных мероприятий по искусственному интеллекту. Проанализированы результаты исследования уровня цифровой грамотности в области искусственного интеллекта у обучающихся 10-11 классов. Результаты диагностики позволили выявить задания, с которыми школьники справились наилучшим образом и проблемные зоны, требующие дополнительного внимания в процессе обучения.

**Ключевые слова:** технологии искусственного интеллекта, внеурочная деятельность, педагогическое проектирование, диагностика цифровой грамотности.

**Введение.** С учетом стремительного развития и внедрения искусственного интеллекта (ИИ) в различные сферы нашей жизни, включая промышленность, здравоохранение, финансы и образование, обучение школьников основам ИИ становится актуальной задачей.

Искусственный интеллект как новый раздел школьного курса информатики рассматривается в монографии Н.Н. Самылкиной, А.А. Салаховой [2]. По мнению авторов, ИИ может быть использован как для сопровождения образовательного процесса, так и в качестве компонента содержания образования.

Внеурочные мероприятия, посвященные изучению и практическому применению принципов и методов искусственного интеллекта, способствуют повышению осведомленности школьников о роли искусственного интеллекта в современном мире, его потенциале и ограничениях. Они также предоставляют возможность углубленного изучения алгоритмов машинного обучения, обработки естественного языка, компьютерного зрения и других ключевых областей, связанных с ИИ. Помимо этого, данные занятия могут способствовать формированию у школьников навыков программирования и аналитического мышления, что является важным элементом подготовки к будущей карьере в области информационных технологий.

Важно отметить, что внеурочные мероприятия создают благоприятную среду для развития у школьников критического мышления и этического восприятия проблем, связанных с использованием искусственного интеллекта. Подобный подход формирует глубокое понимание возможностей и ограничений технологий ИИ, что в свою очередь способствует формированию информационной грамотности и осознанного использования технологий.

**Постановка проблемы.** Ведущие ИТ-компании в рамках всероссийского проекта «Урок цифры» [3] начали разработку внеурочных мероприятий, по-

свящённых цифровым технологиям, в том числе технологиям искусственного интеллекта. Занятия демонстрируют практическое применение ИИ в различных сферах, что повышает интерес школьников к теме и способствует профориентации. Большинство мероприятий бесплатны и доступны онлайн. Анализ сценариев занятий по ИИ от Благотворительного Фонда «Вклад в будущее», Яндекс Учебника и фирмы 1С на платформе Урок Цифры показал, что их основным недостатком является отсутствие разнообразия педагогических приёмов и технологий, соответствующих требованиям обновлённого ФГОС к организации деятельности. Поэтому целью исследования явилось проектирование и апробация методических материалов для организации внеурочных мероприятий по искусственному интеллекту для обучающихся 10-11 классов.

**Материалы и методы.** Изучение и анализ сценариев занятий, размещённых на платформах Урок Цифры, Инфоурок, Мультиурок и Атомный урок позволило выявить лучшие практики и создать шаблон для разработки методических материалов в логике обратного дизайна. Шаблон включает в себя описание целей, задач, методов и материалов занятия, что обеспечивает системный подход к его организации.

В рамках проведенного исследования были спроектированы сценарии четырёх внеурочных мероприятий по следующим темам: Роль искусственного интеллекта в будущих профессиях, Этические аспекты использования искусственного интеллекта, Искусственный интеллект и нейротворчество, Искусственный интеллект в повседневной жизни: от смартфонов до умных городов.

На занятии «Роль искусственного интеллекта в будущих профессиях» каждая группа готовит постер, где описаны по 3 профессии будущего и характеристики умений и навыков, которыми должен владеть специалист.

На внеурочном мероприятии «Этические аспекты использования искусственного интеллекта» организуются дебаты на тему этических аспектов ИИ, с участием разных сторон (ученые, инженеры, философы, политики, общественные деятели).

На занятии «Искусственный интеллект и нейротворчество» обучающиеся в группах создают текст с помощью YandexGPT 2 и иллюстрацию к нему с помощью Kandinsky 3.0.

На внеурочном мероприятии «Искусственный интеллект в повседневной жизни: от смартфонов до умных городов» после рассказа учителя об использовании ИИ в современном мире обучающиеся делятся на 5 групп. Каждая группа создаёт карту умного города. В конце занятия происходит презентация карт.

**Результаты.** Разработанные сценарии занятий прошли апробацию в рамках классного часа «RuCode. Искусственный интеллект» с обучающимися 10-11 классов базовых школ наставников ПГППУ.

В ходе апробации был проведен констатирующий педагогический эксперимент по исследованию уровня цифровой грамотности в области ИИ у обучающихся 10-11 классов. В эксперименте участвовали 58 респондентов.

Используя проект AI4K12 (автор Скай Чхан [1]) были выделены 5 групп умений, которые проверялись в рамках эксперимента:

- понимание принципов работы искусственного интеллекта и его основных направлений;
- умение работать с данными: собирать, обрабатывать, анализировать и визуализировать информацию;
- алгоритмическое мышление: анализировать задачи, разрабатывать алгоритмы и применять их для решения практических задач;
- навыки программирования: использовать языки программирования для создания ИИ-приложений;
- критическое мышление и этическая ответственность: оценивать возможности и ограничения ИИ, его социальные и этические последствия.

Тест включал в себя 10 заданий, по 2 задания на каждое умение. Каждое задание оценивалось в 1 балл. Результаты диагностики представлены на рис. Средний балл составил 6,24 из 10. Можно сделать вывод, что уровень цифровой грамотности в области ИИ у обучающихся в целом удовлетворительный.

Результаты диагностики позволяют выявить задания, с которыми школьники справились наилучшим образом. Это задания на умение работать с данными и алгоритмическое мышление. Ниже представлены формулировки заданий.

Задание 3. Представьте, что вы хотите обучить нейросеть распознавать породы собак. Опишите, какие данные вам понадобятся, как вы будете их собирать и предобрабатывать. Результаты выполнения: 79,31% правильных ответов.




Рис. Результаты диагностики уровня цифровой грамотности обучающихся в области искусственного интеллекта

Задание 4. Вам предоставлена таблица с данными о продажах интернет-магазина за последний год. Опишите, как вы можете визуализировать эти данные, чтобы выявить сезонные тренды и самые популярные товары. Результаты выполнения: 75,9% правильных ответов.

Задание 5. Разработайте алгоритм, который будет находить среднее арифметическое чисел в заданном списке. Результаты выполнения: 77,6% правильных ответов.

Наибольшие затруднения у школьников вызвали задания на понимание принципов работы искусственного интеллекта и его основных направлений, а также навыков программирования и этической ответственности. Приведём примеры заданий.

Задание 2. Выберите три основных направления развития искусственного интеллекта. Результаты выполнения: 20,7% правильных ответов.

Задание 6. Вам необходимо написать программу, которая будет определять, является ли введенное пользователем число простым. Опишите алгоритм решения этой задачи. Результаты выполнения: 50% правильных ответов.

Задание 10. Представьте, что компания разработала систему искусственного интеллекта для оценки кандидатов на работу. Какие этические проблемы могут возникнуть при использовании такой системы, и как их можно решить? Результаты выполнения: 50% правильных ответов.

**Заключение.** Полученные результаты указывают на необходимость дальнейшего развития цифровой грамотности в области искусственного интеллекта. Это можно сделать, включая в учебные планы курсы по основам искусственного интеллекта, а также организуя внеурочные мероприятия.

Подводя итог, можно сказать, что внеурочные мероприятия по искусственному интеллекту для школьников 10-11 классов не только обоснованы с дидактической точки зрения, но и представляют собой важный шаг в подготовке будущих специалистов, способных эффективно взаимодействовать с современными технологиями искусственного интеллекта.

### **Библиографический список**

1. AI literacy in K-12: a systematic literature review. International Journal of STEM Education. – URL: <https://stemeducationjournal.springeropen.com/articles/10.1186/s40594-023-00418-7> (дата обращения: 11.09.2024).
2. Самылкина Н.Н., Салахова А.А. Обучение основам искусственного интеллекта и анализа данных в курсе информатики на уровне среднего общего образования: монография – Москва : МПГУ, 2022. – 242 с.
3. Урок Цифры – URL: <https://урокцифры.рф> (дата обращения: 11.09.2024).

### **DESIGNING AND IMPLEMENTING EXTRACURRICULAR ACTIVITIES ON ARTIFICIAL INTELLIGENCE FOR SENIOR SCHOOL**

*Anna V. Hudyakova*

Str. Sibirskaya, 24, Perm, Russia, 614068  
[ahudyakova@pspu.ru](mailto:ahudyakova@pspu.ru)

The description of extracurricular activities on artificial intelligence is presented. The results of a study of the level of digital literacy in the field of artificial intelligence among students in senior school are analyzed. The diagnostic results made it possible to identify the tasks that the students coped with in the best way and problem areas that require additional attention in the learning process.

**Keywords:** artificial intelligence technologies, extracurricular activities, pedagogical design, diagnostics of digital literacy.

## Секция: Искусственный интеллект, лингвистика и обработка текста

УДК 004.89

### ВНЕДРЕНИЕ ТЕХНОЛОГИЙ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ В МЕССЕНДЖЕРЫ

*Кузьмин Алексей Николаевич*

Тюменский индустриальный университет,  
625000, Россия, г. Тюмень, ул. Володарского, 38  
p9823@bk.ru

В статье рассматривается проект внедрения технологий больших языковых моделей в мобильный клиент мессенджера. Описываемое мобильное серверное приложение позволяет повысить продуктивность работы с чатом Telegram. Разработанный MVP предназначен для менеджеров, директоров, занятых и рядовых пользователей мессенджеров с целью сокращения общего времени ознакомления с историей переписки. В первой итерации продукт предназначен для пользователей мессенджера Telegram.

**Ключевые слова:** мессенджер, искусственный интеллект, LLM, мобильное приложение, модифицированный клиент, языковые модели, чат.

**Введение.** В современных условиях увеличения объема информации в мессенджерах, таких как Telegram, возрастает временная нагрузка [1] на пользователей, особенно на тех, кто сталкивается с большими объемами переписки и рассылок. Из этого следует снижение продуктивности работы с мессенджером. Применение языковых моделей значительно повысит продуктивность работы с высокоактивными чатами. Упростит вычленение информации из потока данных. Применение больших языковых моделей (LLM) является перспективным решением данной проблемы, позволяющим повысить продуктивность работы с мессенджерами и сократить время на обработку информации.

**Постановка задачи.** Цель данной работы разработка концепции мобильного клиента, который выступает в качестве стороннего клиента для мессенджера Telegram. Уникальность продукта – в удобстве для пользователя в форме мобильного приложения. Мобильное приложение обладает всеми функциями официального клиента, и обладает сторонним функционалом больших языковых моделей. Проект не нарушает правила распространения и разработки сторонних клиентов для Telegram [2].

Продукт применим ко всем пользователям мессенджеров. Приоритет дан группе пользователей, классифицируемой, как менеджеры, «занятые люди». Планируется что продукт будут использовать в целях сокращения времени на прочтение диалогов и рассылок, поиск значимой информации в разговоре.



**Исследование предметной области.** В ходе исследования предметной области были рассмотрены возможности [3] больших языковых моделей и разработаны следующие концепции применения технологий LLM в мессенджере:

- Краткий пересказ диалогов чатов и рассылок рассматривается как главный продающий функционал приложения модуль. Активный или принужденный пользователь заинтересован в сокращении затрачиваемого времени на ознакомление с историей чата. Применение технологий LLM позволит глубоко анализировать содержимое переписки и составлять выжимку диалогов.

- Вычленение фактов ключевой модуль для альтернативного подхода к информации, располагающейся в чате. Так, важные события или фактическая информация об объектах дискуссии вычленяется ИИ, а мобильный клиент предоставляет ее в емкой форме.

- Модуль досье интересен для использования HR специалистами, менеджерами по работе с клиентами. Полезен для поиска фактов о собеседнике [4] и уточнения информации о нем.

Для реализации этих функций в мобильном приложении используется серверная архитектура (рис. 1), где мобильный клиент отправляет запросы на сервер для обработки переписки с помощью языковых моделей. Сервер wattwil занимается комбинированием исходных данных и запроса в промпт [3] для языковой модели. Также сервер решает какую LLM использовать. Обработка данных производится на стороннем сервисе языковой модели, после чего результаты передаются обратно на мобильное приложение и сохраняются на сервере wattwil для восстановления обработанных данных после переустановки приложения или для дальнейшего использования при формировании промптов.

**Проектирование продукта.** За основу мобильного клиента взят исходный код мобильного клиента Telegram, дополняемый функциями обработки чатов, с помощью серверного приложения. Выбранный подход обладает следующими преимуществами:

Модульность решения – мобильный клиент дорабатывается отдельно от серверного приложения;

- Надежность – серверное приложение гарантирует доступ к языковым моделям независимо от региона пользователя;

- Удобство пользователя – серверное приложение сохраняет обработанные данные, что повышает удобство и скорость перехода на сторонний клиент для Telegram;

- Независимость – серверное приложение легко меняет языковые модели при необходимости;

- Универсальность – серверное приложение работает с любой платформой пользователя, нужен только клиент.

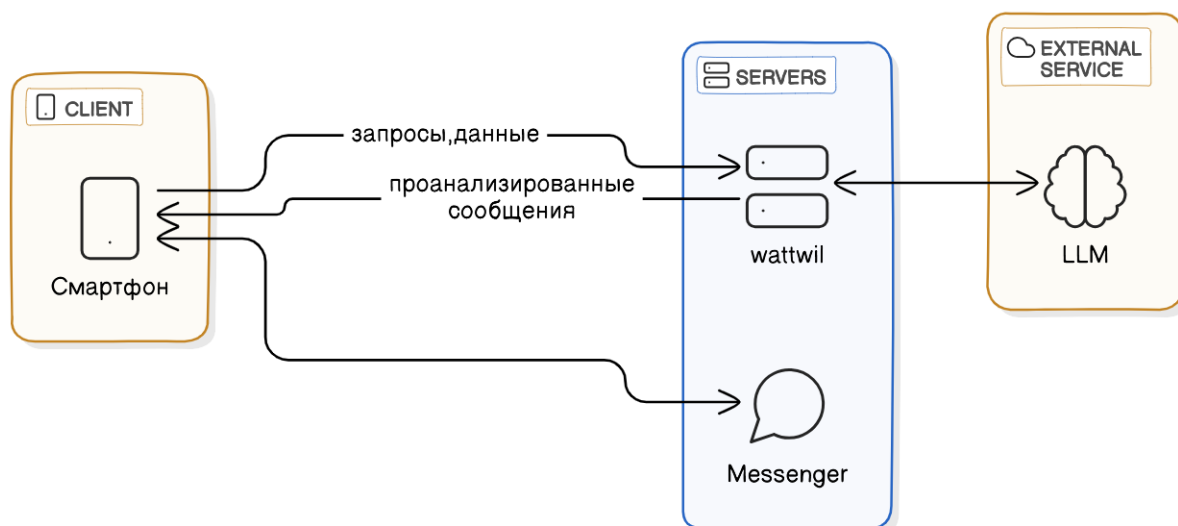


Рис. 1. Архитектура решения

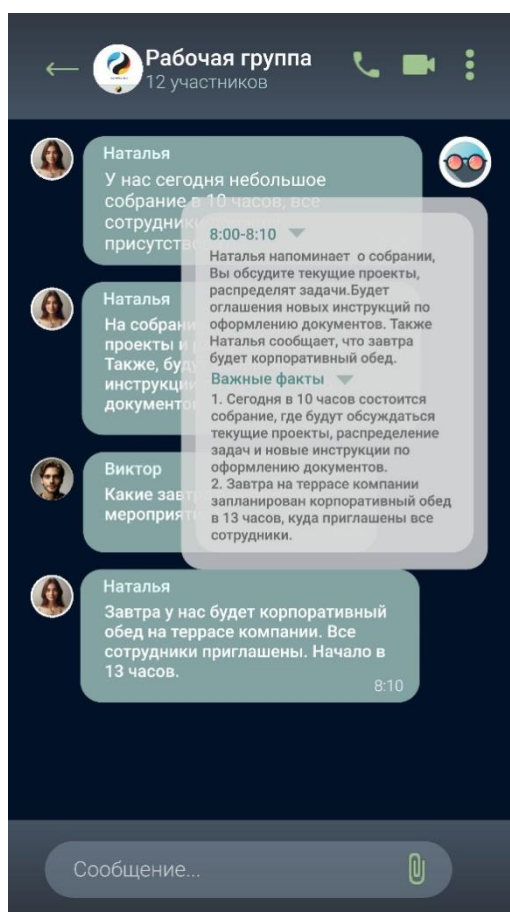


Рис. 2. Пример интерфейса мобильного клиента

Разработанные концепции на стороне мобильного клиента работают следующим образом: пользователь мобильного приложения состоит в чатах, сообщения из чатов в соответствии заданным пользователем настройкам собираются в пакеты для обработки языковыми моделями. Мобильный клиент отправляет такой пакет с пометкой необходимого метода обработки на сервер проекта. Сервер проекта в свою очередь формирует из данных пакета запрос к

языковой модели. Полученный ответ сохраняется на сервере и передается на клиент пользователя. Мобильный клиент пользователя размещает полученный ответ в интерфейсе в соответствии результата метода обработки. Например, для метода краткого пересказа результат обработки в интерфейсе мобильного клиента пользователя будет выглядеть как на рис. 2.

**Заключение.** В результате исследования был разработан прототип мобильного приложения, способного значительно повысить продуктивность работы с информацией в мессенджерах. Приложение позволяет пользователям сокращать время на ознакомление с перепиской за счет использования технологий LLM. Разработанное решение предоставляет гибкие возможности для адаптации под различные сценарии использования, что делает его полезным как для менеджеров, так и для других категорий пользователей, которым требуется оперативная обработка информации. В перспективе возможно добавление новых функций и модулей, таких как комбинирование методов обработки и расширение поддерживаемых мессенджеров.

### Библиографический список

1. Доля пользователей Telegram достигла почти половины населения России Как платформа Павла Дурова конкурирует с YouTube и WhatsApp. [Электронный ресурс]. Режим доступа: [https://www.rbc.ru/technology\\_and\\_media/06/02/2024/65c0bc179a7947176b534458](https://www.rbc.ru/technology_and_media/06/02/2024/65c0bc179a7947176b534458)
2. Telegram API Terms of Service. [Электронный ресурс]. Режим доступа: <https://core.telegram.org/api/terms>
3. Панда П., Сычева А. В. ChatGPT. Мастер подсказок, или как создавать сильные промты для нейросети. 2024.— 203 с.
4. Антон Рыбаков, Вадим Челпанов Анализ личности через профиль соцсетей. Интернет-разведка. 2023. 164 с.

## IMPLEMENTATION OF LLM TECHNOLOGIES IN MESSENGERS

***Kuzmin Aleksey***

Industrial University of Tyumen,  
Str. Volodarskogo, 38, Tyumen, Russia, 625000  
p9823@bk.ru

The article deals with the project of introducing large language model technologies into the mobile client of messenger. The described mobile server application allows to increase the productivity of work with Telegram chat. The developed MVP is intended for managers, directors, busy and ordinary users of messengers in order to reduce the total time of familiarization with the history of correspondence. In the first iteration, the product is designed for Telegram messenger users.

**Keywords:** messenger, artificial intelligence, LLM, mobile application, modified client, language models, chat.

## ОЦЕНКА СВЯЗНОСТИ ТЕКСТА МЕТОДАМИ КЛАСТЕРИЗАЦИИ

*Калабин Александр Леонидович*

Тверской государственный технический университет  
170023 г. Тверь наб. Аф. Никитина, 22  
akalabin@yandex.ru

Предложена оценка связности текста методами компьютерной лингвистики и Text Mining – кластеризации (5 разных алгоритмов). Определение связности текста заключается в разбиении целого текста на части с их последующей кластеризацией и анализе состава кластеров, состоящих из последовательных или случайных частей исследуемого текста. Рассмотрены 4 примера применения к 3-м текстам. Получены согласованные результаты для всех примеров: сильно, частично и слабо связанный текст.

**Ключевые слова:** связность текста, Text Mining, кластеризация.

**Введение.** Связность – основной критерий текстуальности, свойство организованный минимальный единицы дискурса / текста («по существу свойством быть текстом» [1].

Как оценить полноту связанности фабулы, взаимоотношений персонажей и событий? М. Л. Макаров дает определение данным текстовым категориям и разграничивает их по сферам влияния [2]. Когезия – это «формально-грамматическая связанность дискурса, определяется различными типами языковых отношений между предложениями, составляющими текст, или высказываниями в дискурсе...». Когерентность текста есть результат взаимодействия логико-семантического, синтаксического и стилистического видов когезии, причем основой когерентности является именно логико-семантическая когезия, предложений.

Определимся с понятиями: связанность и связность – разные вещи. В русском языке эти два слова имеют разные значения: связанный означает (в главном значении) «несвободный», а связный – «логически стройный, последовательно изложенный» [3]. Определения связности в современной лингвистике разнообразны, но весьма неточны: часто утрачивается именно приведённое выше основное значение. Понятия связности и цельности текста (от лат. *textus* «ткань; сплетение, связь, сочетание») определяются через понятия когерентность и когезия – исключительно лингвистические элементы, обеспечивающие связность текста [4]. Однако нами не найдены проверенные, объективные методы количественного измерения этих свойств.

**Постановка задачи и формирование DataSet.** Нами предлагается следующий подход оценки связности текста, основанный на использовании методов Text Mining или компьютерной лингвистики. При этом обратим внимание, что термин компьютерной лингвистики – кластеризации [5] заключается в определении набора данных (текстов) имеющих общие или близкие характеристики и поэтому связные между собой. Задача кластеризации состоит в разде-

лении исследуемого множества объектов на группы "похожих" объектов, называемых кластерами [5] и анализе их состава.

Для проведения экспериментов использовалась разработанная нами программная системы анализа текстов, которая проверена на работоспособность и включает различные методы кластеризации. В качестве данных для тестирования программной системы были организованы 3 группы массивов текстовых данных:

1) Пример Китай (5 документов) для отладки из [6].

2) Статьи о (HDD, SSD) и (SSD, MB) (45 документов из <http://www.ferra.ru/>)

Работоспособность разработанной программной системы анализа текстов подтверждается результатами тестирования на приведенной выше выборке документов.

Предварительная обработка данных в системе TextStageProcessor включает в себя три этапа и использует настроенную для русского языка библиотеку ruMorphu2. Значительному сокращению количества термов и снижению уровня стохастической зависимости между значимыми словами способствует приведение к нормальной форме или морфологическая обработка текста.

**Тестирование алгоритмов кластеризации.** Результаты работы алгоритмов (Таблица 1) оцениваются по таким критериям как ошибка (E), правильность (A), точность (P) и полнота (R) [6], а также, предлагаемая нами, суммарная величина точности, полноты и правильности ( $I = P + R + A$ ), которая может иметь максимальное значение 3, при 100% правильности работы метода.

Для схожих категорий HDD и SSD по усредненному критерию I наиболее эффективным методом кластеризации метод восходящей иерархии (2,72) и метод DBSCAN (2,63). Хуже всего справился с исходной выборкой данных метод К-средних (2.2).

Эксперименты показали, что Hierarchical > DBSCAN > SMiddle > Spectral > K-Means означает «эффективнее», где DBSCAN – плотностной метод пространственной кластеризации для «шумных» данных; Hierarchical – метод восходящей иерархии; SMiddle – метод с-средних; Spectral – Спектральная кластеризация; K-Means – метод k-средних.

Проект расположен в веб-сервисе для хостинга IT-проектов и их совместной разработке по адресу: <https://github.com/mhyhre/TextStageProcessor> [7]. Предлагаем использовать наше приложение в Вашей работе.

**Исследование предметной области.** Предлагается использование кластеризацию для оценки связности текста документа [8]. Пусть текст документа состоит из нескольких выделенных частей или мы сами разбиваем его на части, которых должно быть не менее 4-5. Каждую из частей представляем в виде отдельного текстового файла – документа. При этом скрывается информация о последовательности следования этих частей в целом тексте. Определяем, как эти отдельные части связаны между собой, друг с другом, с помощью методов кластеризации. Близкие по свойствам документы, части текста, попадут в один кластер.

**Оценка качества работы методов кластеризации  
по интеграционному критерию с учетом препроцессинга**

Данные Алгоритм TextStageProcessor	Схожие	Разные
	HDD и SSD	SSD и MB
Классификация без учителя		
метод восходящей иерархии	2,72	3,00
DBSCAN	2,63	3,00
метод с-средних	2,44	3,00
Спектральная кластеризация	2,32	3,00
метод k-средних	2,21	3,00

Предполагаем, что если текст связан, то определённые алгоритмом кластеры будут состоять из последовательных частей исследуемого текста. При этом должно выполняться два условия, во-первых, каждый кластер должен состоять из одной или нескольких последовательных частей и не содержать непоследовательных частей исходного текста. Во-вторых, количество кластеров должно быть меньше частей текста, как минимум на 2, так что бы, хотя один кластер состоял из нескольких документов, частей текста. Пример – допустим, есть пять частей текста, то, если текст сильно связан, в первый кластер могут входить, например, части (1 2 3) или (1 2) этого текста и во второй кластер, соответственно, (4 5) или (3 4 5) последовательные части, например

$$(1\ 2\ 3\ 4\ 5) = (1\ 2\ 3) + (4\ 5) = (1\ 2) + (3\ 4\ 5) = (1) + (2\ 3) + (4\ 5).$$

Пример не связанности частей текста для документа из пяти частей, может быть, например, если в первый кластер входит, например, (1,3,5) или (2,4) части этого текста и во второй кластер (2,4) или (1,3,5) не последовательные части этого текста

$$(1\ 2\ 3\ 4\ 5) \nrightarrow (1,3,5) + (2,4) \nrightarrow (1\ 3) + (2\ 4\ 5) \nrightarrow (1) + (2\ 4) + (3\ 5).$$

Количественную оценку степени связности определим через индекс связности  $I_c$ , как минимальное число перестановок частей исследуемого текста между определенными алгоритмом кластерами, которое необходимо совершить для того чтобы каждый кластер состоял только из одной или нескольких последовательных частей текста, не изменяя число кластеров. Определим, что чем меньше индекс связности, тем больше связность текста. Перестановку определим как перенос любой части текста из одного кластера в любой иной кластер. Общие количество перестановок будет являться мерой не связности, не однородности всего текста.

Например, для примера 1

$$(1\ 2\ 3\ 4\ 5) = (1\ 2\ 3) + (4\ 5) = (1\ 2) + (3\ 4\ 5) = (1) + (2\ 3) + (4\ 5) \rightarrow I_c=0.$$

во всех трех случаях перестановок не требуется, поэтому значение минимально  $I_c=0$  и следовательно связность максимальна.. Рассмотрим пример 2, когда кластера содержат не последовательные части текста

$$(1\ 2\ 3\ 4\ 5) \diamond (1,2,3,5) + (4) \rightarrow (1,2,3) + (4,5) = (1\ 2\ 3\ 4\ 5) \rightarrow I_c=1,$$

переставили 5-ю часть во 2-й кластер;

пример 3,

$$(1\ 2\ 3\ 4\ 5) \diamond (1,3,5) + (2,4) \rightarrow (1,2,3,5) + (4) \rightarrow (1,2,3) + (4,5) = (1\ 2\ 3\ 4\ 5) \rightarrow I_c=2,$$

переставили 2 часть в 1-й кластер; переставили 5 часть во 2-й кластер;

или

$$(1\ 2\ 3\ 4\ 5) \diamond (1,3,5) + (2,4) \rightarrow (1,4,3,5) + (2) \rightarrow (1,2) + (3,4,5) = (1\ 2\ 3\ 4\ 5) \rightarrow I_c=2,$$

переставили 4-ю часть в 1-й кластер; переставили 1 часть во 2-й кластер;

пример 4,

$$(1,2,3,4,5,6,7,8) \diamond (1,3,6,7)(2,4,5,8) \rightarrow (3,6,7)(1,2,4,5,8) \rightarrow (6,7)(1,2,3,2,4,5,8) \rightarrow (1,2,3,4,5,6,7,8) = (1,2,3,4,5,6,7,8) \rightarrow I_c=3,$$

переставили 1 часть во 2-й кластер; переставили 3 часть во 3-й кластер; переставили 8 часть в 1-й кластер.

Рассмотрим примеры текстов произведений Ф.М. Достоевского, Л.Н. Толстого. И.С. Тургенев список, которых приведен в Таблице 2, в правом столбце показана определенная суммарная оценка их связности. Сумма получена использованием пяти различных методов кластеризации для повышения объективности получаемой оценки.

Таблица 3 содержит оценки связности текста протестированными методами кластеризации для получения более объективной картины. Столбцы 1-7 соответствуют текстам под этими номерами из табл. 2. Столбцы а-ж показывают связность текста, число минимальных перестановок частей исследуемого текста между определенными алгоритмом кластерами, которое необходимо для того чтобы каждый кластер состоял только из одной или нескольких последовательных частей текста соответствующего текста определенным методом.

Рассмотрены примеры применения к 5-м текстам Ф.М. Достоевского. Определено, что «Чужая жена и муж под кроватью» сильно связан, тексты 1,2 и 3 (Табл. 3) частично связаны, а текст «Слабое сердце» слабо связан. В произведениях Ф.М. Достоевского получена относительно высокая оценка связности текста. «Сон смешного человека» «Хозяйка» суммарный (пятью разными методами кластеризации) индекс связности – 3, тогда как Л.Н. Толстого «Отец Сергей» и И.С. Тургенев «Бретер» 10 и 8. Отсюда следует, что условная относительная количественная оценка связности выше примерно в 3 раза, что для количественной оценки существенно.

Таблица 2

## Тексты и суммарный индекс связности

	Произведение	Индекс связности
1	Сон смешного человека	3
2	Хозяйка	3
3	Слабое сердце	4
4	Крокодил	3
5	Чужая жена и муж под кроватью	2
6	Отец Сергей Л.Н. Толстого	10
7	Бретер И.С. Тургенев	8

Таблица 3

## Оценка связности текста разными методами

Метод	1	а	2	б	3	в	4	г
DBSCAN	(1,2)(3)(4,5)	0	(1-6)	0	(1-7)	0	(1,3)(2)(4)	1
Hierarchical	(1,2)(3)(4,5)	0	(1-6)	0	(1,5,6,7)(2)(3,4)	1	(1,3)(2)(4)	1
SMiddle	(1,2,5)(3,4)	1	(1,2,6)(3,4,5)	1	(1,2,3,4)(5,6)(7)	0	(1,2,3)(4)	0
Spectral	(1,2,5)(3,4)	1	(1,2,3,6)(4,5)	1	(1,2,4)(5)(3,6,7)	1	(1)(2,3)(4)	0
K-Means	(2,3,4)(1,5,6)	1	(1,2,3,6)(4,5)	1	(1,4,7)(2)(3,5,6)	2	(1,4)(2,3)	1
	$\Sigma a$	3	$\Sigma b$	3	$\Sigma v$	4	$\Sigma g$	3

Метод	5	д	6	е	7	ж	$\Sigma$
DBSCAN	(1-6)(7)	0	(1,3,5,6,7,8)(2,4)	2	(1,3,6)(2,4,7,8)(5)	0	3
Hierarchical	(1-4)(5,6,7)	0	(1,2,4)(3,5,6,7,8)	1	(1,2,4)(3,6)(5)	1	4
SMiddle	(1-4)(5,6,7)	0	(1,3,6,7)(2,4,5,8)	3	(1,3,6,7)(2,4,5,8)	3	8
Spectral	(1-4)(5,6)(7)	0	(1,3,6)(2,4,5,7,8)	2	(1,3,6)(2,4,7,8)	2	7
K-Means	(1,3,4,7)(2,5,6)	2	(1,3,6)(2,4,5,7,8)	2	(1,3,6)(2,4,5,7,8)	2	11
	$\Sigma d$	2	$\Sigma e$	10	$\Sigma j$	8	

**Заключение.** Полученная объективная высокая оценка связности текста произведений Ф.М. Достоевского подтверждает цельность текста и его последовательную логичность развития.

Предложена оценка связанности текста методами кластеризации (5 алгоритмов). Определена количественная мера степени связности – индекс связности  $I_s$ , как минимальное число перестановок частей исследуемого текста между определенными алгоритмом кластерами. Рассмотрены примеры применения к разным текстам. Текст рассказа Ф.М. Достоевского «Сон смешного человека» сильно связан, текст повести Ф.М. Достоевского «Хозяйка» частично связан, текст повести Л.Н. Толстого «Отец Сергей» слабо связан. Данный подход планируется применить к анализу научной и технической литературы.



## Библиографический список

1. Кронгауз М.А. Семантика. М: Академия, 2005. 352 с.
2. Макаров М. Л. Основы теории дискурса. М.: Гнозис, 2003. – С. 190
3. Сорокин Ю. А. Текст: цельность, связность, эмотивность // Аспекты общей и частной лингвистической теории текста. – М., 1982, с. 61 – 73.
4. Ефремова Т.Ф. Современный толковый словарь русского языка. В 3 томах.// 2005 год. Издательства: АСТ, Астрель, Харвест, Lingua.
5. Барсегян, А. А. Анализ данных и процессов: учеб. пособие / А. А. Барсегян, М. С. Куприянов, И. И. Холод, М. Д. Тесс, С. И. Елизаров. – 3-е изд., перераб. и доп. – СПб.: БХВ-Петербург, 2009. – 512 с.: ил.
6. Автоматическая обработка текстов на естественном языке и анализ данных: учеб. пособие. / Е.И. Большакова [и др.]. – Москва: НИУ ВШЭ. – 2017. – 268 с.
7. Калабин А.Л., Туляков А.В. Программная система для анализа текстов // Сб.трудов 31-й Междун.конф. Математ. методы в технике и технологиях. г. Санкт-Петербург, 10 –14 сентября 2018 г., 2018. Т. 8. с. 55-58.
8. Калабин А.Л. Оценка связанности текста методами компьютерной лингвистики // СПб. Изд-во Политехн. ун-та, 2018. – 112 с. В кн. Сб.трудов 31-й Междун.конф. Мате математические методы в технике и технологиях. Т. 8 г. Санкт-Петербург, 10 –14 сентября 2018 г., –с. 59 -63

## EVALUATION OF TEXT CONNECTIVITY BY CLUSTERING METHODS

*Kalabin Alexander Leonidovich*

Tver State Technical University  
170023 Tver nab. Af. Nikitin, 22  
akalabin@yandex.ru

An assessment of the coherence of the text by methods of computational linguistics and Text Mining clustering (5 different algorithms) is proposed. The definition of text connectivity consists in dividing the whole text into parts with their subsequent clustering and analyzing the composition of clusters consisting of consecutive or random parts of the text under study. 4 examples of application to 3 texts are considered. Consistent results were obtained for all examples: strongly, partially and weakly related text.

**Keywords:** text connectivity, Text Mining, clustering.

## ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ДНЕВНИКА Ф.П. ЛИТКЕ: БОЛЬШИЕ ЯЗЫКОВЫЕ МОДЕЛИ И МЕТАДААННЫЕ В ПРОЦЕССЕ ОБРАБОТКИ ЕСТЕСТВЕННОГО ЯЗЫКА

*Лаптев Антон Константинович*

Национальный исследовательский университет «Высшая школа экономики»,  
101000, Россия, г. Москва, ул. Мясницкая, 20  
aklaptev@hse.ru

В статье представлен практический эксперимент по использованию большой языковой модели на базе YandexGPT для анализа автоматически распознанного (с помощью специально обученной модели) рукописного текста из дневника адмирала Ф.П. Литке. Такая «связка» нейронных сетей позволила получить валидные метаданные, ставшие основой для проведения тематического моделирования корпуса рукописей дневника Ф.П. Литке. В результате, помимо получения распознанной рукописи середины XIX в., удалось провести интеллектуальный анализ представленного текста с помощью готовых веб-инструментов. На практике это позволяет говорить о возможности «безшовно» проводить полноценный интеллектуальный анализ больших массивов рукописей без деления этого процесса на отдельные локальные итерации.

**Ключевые слова:** нейросетевые технологии, XIX в., интеллектуальный анализ текста, обработка естественного языка, большие языковые модели.

**Введение.** Интеллектуальный анализ текста<sup>1</sup> (text mining) в контексте исторической науки подразумевает под собой автоматическое извлечение сведений из корпуса исторических источников. Сложность и особенность такого источника (в отличие от других данных, например математических расчетов) заключается в том, что исходная информация является неформализованной: ее нельзя описать простой математической функцией. Здесь требуется дополнительный шаг в виде организации и структурирования данных из текста для последующей аналитики и проведения комплексного анализа. Для математических алгоритмов необходимы те же сведения (или обобщенные данные), которые старается обнаружить и зафиксировать (письменно или в уме) человек-исследователь, который начинает работу с историческим источником. К таким данным относятся как классические атрибуты (время, дата, место создания документа, авторство, тип документа и т.д.), а также иные характеристики (ключевые слова, упоминаемые лица, организации или места, краткая аннотация документа, числовые данные и т.д.).

Такие данные приобретают ключевое значение для процесса структурирования, а значит и интеллектуального анализа исторической рукописи. Для их

---

© Лаптев А.К., 2024

<sup>1</sup> Здесь и далее интеллектуальный анализ текста подразумевает под собой процесс, интегрированный в проведение исторических исследований, а термин «текст» подразумевает под собой информацию, которая непосредственно содержится в исторических источниках. При этом, указанные документы, которые легли в основу настоящей работы, по своему типу относятся к рукописным историческим документам (конкретно в исследовании проводится анализ личного дневника Ф.П. Литке).

наименования будет более правильно использовать термин «метаданные». Так, исследователь интуитивно работает с такой ключевой информацией и рефлексивно фиксируется на ней при работе с историческим источником. С другой стороны, специализированный алгоритм (нейронная сеть) не понимает разницы между типами данных без дополнительного обучения и донастройки: первоначально все данные из текста воспринимаются им, как равновесные и равнозначные.

Одним из современных методов, которые позволяют добиться решения поставленной проблемы по выявлению метаданных, выступают нейронные языковые модели, которые получили распространение после 2018 г., когда компанией OpenAI была представлена модель GPT (Generative pre-trained transformer)<sup>2</sup>, способная к выполнению широкого спектра задач за счет обучения на больших объемах данных. Такие нейронные языковые модели с достаточным обучением и подсчетом параметров могут отражать и «схватывать» большую часть синтаксиса и семантики человеческого (естественного) языка. Эта особенность стала основным аргументом для нашего исследовательского коллектива при привлечении LLM в качестве инструмента для интеллектуального анализа такого исторического источника, как личный дневник адмирала Федора Петровича Литке. Главной задачей, которая была нами определена, стало выявление метаданных, которые должны сформировать как общее представление об источнике, так и дать возможность понимания отдельных сегментов дневника Ф.П. Литке. В рамках проведения исследования была выбрана LLM YandexGPT. Ключевым критерием выбора стал тот факт, что основным источником для обучения языковой модели стало использование текстов на русском языке. Это принимает особенное значение в связи с тем, что дневник Ф.П. Литке датируется серединой XIX в., и текст в нем использует как устаревший синтаксис, так и словоформы, характерные для позапрошлого века.

Сам исторический источник представляет из себя корпус рукописных документов и исследовательским коллективом была разработана и применена специализированная нейронная сеть для первоначальной расшифровки и перевода дневника в машиночитаемый текст. В результате применения обученной нейронной сети, получилось полностью расшифровать все четыре тома дневника Ф.П. Литке. В рамках работы специализированного алгоритма был получен машиночитаемый текст, который характеризуется крайне низким процентом ошибок CER и WER<sup>3</sup>. Так, было верно распознано более 98% символов (букв) в рукописном тексте дневника. При этом непосредственное обучение нейронной сети выстраивалось не весьма малом объеме распознанных данных (около 20 распознанных «вручную» листов), которые были подготовлены людьми (так называемое «обучение с учителем»). Такое стало возможно благодаря разработанным командой исследователей комплексу математических алгоритмов, спо-

---

<sup>2</sup> Генеративный предобученный трансформер.

<sup>3</sup> CER – частота ошибок в символах, WER – частота ошибок в словах. Показатели фиксируются за счет сравнения текстовых блоков, распознанных математическим алгоритмом с контрольной группой – этим же текстовым блоком, но распознанным человеком «вручную».

способных к высокому уровню распознавания исторической рукописи на малом объеме данных для предварительного обучения [1].

Сочетания результатов работы такой специализированной нейронной сети и обобщенная интерпретация расшифрованного массива текста с помощью привлечения алгоритмов LLM будет достаточно для того, чтобы дать исследователю необходимую информацию о тексте и самую общую информацию об исследуемом документе.

**Практическая часть работы с LLM.** В рамках исследования для языковой модели Yandex GPT был сформулирован пул запросов (инструкций). Они были составлены определенным образом (ряд последовательных вопросов) и в нашем представлении давали бы перечень сведений (метаданных), который позволил бы структурировать рукопись, которая уже была расшифрована с помощью специально разработанной нами нейронной сети. Вместе с этим это дало бы возможность по достижению практических исследовательских задач (анализу текста) с помощью привлечения математических методов статистики и распределения вероятностей применимо к конкретному историческому источнику (дневнику адмирала Ф.П. Литке).

В связи с тем, что интерфейс YandexGPT базируется на загрузке текстового фрагмента определенного размера, весь массив расшифрованного текста второго тома дневника был разделен на условные блоки текста размером, который был в пределах 4500 токенов.<sup>4</sup> В нашем случае это приблизительно соответствовало 5 страницам реального дневника Ф.П. Литке. Такой объем был выбран исходя из конкретных практических условий: запрос и ответ на него в сумме не должен был превышать 8000 токенов, что установлено правилами YandexGPT.

Формат запроса не менялся относительно каждого блока текста и выглядел следующим образом: *«Шаг за шагом проанализируй представленный текст. Предоставь следующую информацию: 1) Ключевые слова, характерные для текста. Укажи ключевые слова (не меньше 8 и не больше 14) в порядке от самого релевантного к менее релевантному. 2) Основные эмоции, которые можно выделить для текста. Поставь их в порядке от самого релевантного к менее релевантному. 3) Имена собственные, указанные в представленном тексте (максимально точно). 4) Места и топонимы, упомянутые в представленном тексте (максимально точно).»*.

Целью такого запроса было получение метаданных, которые должны были сформировать пул данных, которые были объединены в 3 словаря: 1) Эмоции, 2) Персоналии, 3) Места и топонимы. Также это дало возможность собрать импровизированную контрольную группу «ключевые слова», в которую вклю-

---

<sup>4</sup> Токены – это последовательности символов, на которые YandexGPT API разбивает текст. В контексте нейросетей, термин «tokens» (токены) обычно относится к минимальным единицам, на которые разбивается входной текст или последовательность символов перед подачей на обработку модели. Токеном может быть одна буква, одно слово или даже целая фраза, в зависимости от типа и задачи модели. Слово может представлять как один токен, так и занимать размер в несколько токенов в зависимости от используемых алгоритмов анализа объема текста. Для YandexGPT вопрос и ответ вместе могут содержать не больше 8000 токенов.

чались все значимые (с точки зрения алгоритма) данные, которые могли входить в один из трех словарей (например, «Зимний дворец» входил как в словарь ключевых слов, так и в словарь мест и топонимов). С точки зрения статистического анализа, зафиксированная динамика в каждом из трех представленных словарей должна коррелировать с динамикой, которую будет показывать словарь «ключевые слова» относительно каждой из категорий.

**Персоналии.** При проведении анализа словаря «Персоналии», были использованы такие инструменты, как поиск самых часто встречающихся слов в корпусе документов (частотность слов). В результате, было получено, что самыми упоминаемыми являются: «К.Н.», «Г-рь», «Наследник», «В.К.М.Н.», «Григорий» и «Имп.»<sup>5</sup>. Данные здесь вполне коррелируют с логикой: во втором томе дневника Ф.П. Литке центральное место занимает наследник Константин Николаевич. Частота упоминания его в дневнике существенно выше, чем других персоналий (47 упоминаний при условии, что у термина «государь» всего 19 упоминаний). Отдельный интерес представляет достаточно высокое присутствие в тексте упоминаний Великой княгини Марии Николаевны. При этом интересны и связанные с ней частотные повторения в дневнике: по этому показателю Мария Николаевна находится выше, чем упоминания императрицы (13 против 10). График коллокаций<sup>6</sup> (сетевой график слов с более высокой частотой, которые появляются поблизости) показывает, что к ключевому слову «В.К.М.Н.» наиболее близко стоят «императрица», «государь» и «К.Н.», а коллокацией (совместно встречаемым словом) для «В.К.М.Н.» выступает «дворец». Мы можем предположить, что Федор Петрович достаточно высоко оценивал положение Великой княгини Марии Николаевны при дворе и фиксировал это на страницах своего дневника, как важное и состоятельное замечание.

В рамках полученных результатов неизбежно возникает вопрос: насколько вероятно, что большая языковая модель позволяет подсветить исследовательские вопросы, актуальные для того или иного исторического источника? Например, если мы предварительно знакомы с рукописью и интуитивно понимаем содержание ее метаданных (даты, события, персоналии, места, эмоции и т.д.), но, вместе с этим, мы встречаем определенные «отклонения»? В приведенном дневнике таким неявным сюжетом или «отклонением» выступает роль Великой княгини Марии Николаевны в рамках изучаемого дневника и ее упоминаний со

---

<sup>5</sup> Ряд упоминаний были приведены «к единому знаменателю» на этапе обработки полученных от языковой модели данных. Например, упоминания Великой Княгини Марии Николаевны по-разному отражались автором. Он мог использовать только инициалы «М.Н.» либо указывать ее статус «В.К. М.Н.», или просто прибегать к сокращениям «Вел. Кн. Мар. Ник.». Для удобства статистического анализа вся эта вариативность была сведена к единой форме представления конкретной личности – «В.К.М.Н.». Данное действие не представляет серьезной сложности для ее автоматизации. Видится, что в будущем исследователь сможет объединять схожие имена и указания на людей в единые блоки метаданных на основе предложений со стороны нейронных сетей или более простых математических алгоритмов.

<sup>6</sup> Здесь мы понимаем под коллокациями совместно встречаемые слова, которые наиболее часто фиксируются рядом с ключевыми словами. Такая терминология характерна для инструментов сетевого анализа текста. (См. Voyant Tools: веб-пространство для чтения и анализа цифровых текстов. <https://voyant-tools.org/> Дата обращения: 27.07. 2024.)

стороны Ф.П. Литке). Мы можем предположить то, что такие «отклонения» (артефакты), которые мы получаем при выявлении метаданных для изучаемого текста (в первую очередь статистические данные) могут указывать (предлагать) исследователю возможные направления дальнейших научных изысканий.

**Места и топонимы.** Для выстраивания визуального представления дневника Федора Петровича, был привлечен инструмент «DreamScape». Благодаря ему мы смогли вычлениить географические объекты (города, упоминаемые в дневнике), а также их логические связи с массивом текста дневника, чтобы выстроить визуальную карту внутритекстовых связей в привязке к конкретным географическим местам (такие связи изображаются в виде линий, связывающих различные города). Наибольшими связями (связующими центрами) во втором томе выступают два города: это Петербург и Париж. Именно они наиболее часто упоминаются автором дневника в контексте описания различных событий и людей. Вместе с этим, описанное в тексте второго тома путешествие Ф.П. Литке в Европу неизменно максимально полно сопрягалось с такими географическими местами, как Лондон, Париж, Гамбург, Берлин, Варшава и Дармштадт. Самыми упоминаемыми зарубежными странами (по плотности географических привязок) в порядке убывания выступают: Швейцария, Германия, Англия, Польша, а также Бельгия и Нидерланды. Удивительно, но Франция, за редким исключением, представлена в дневнике лишь связями, которые выстраивает Париж. Остальные города либо не представлены вовсе, либо имеют весьма малое упоминание в тексте Литке.

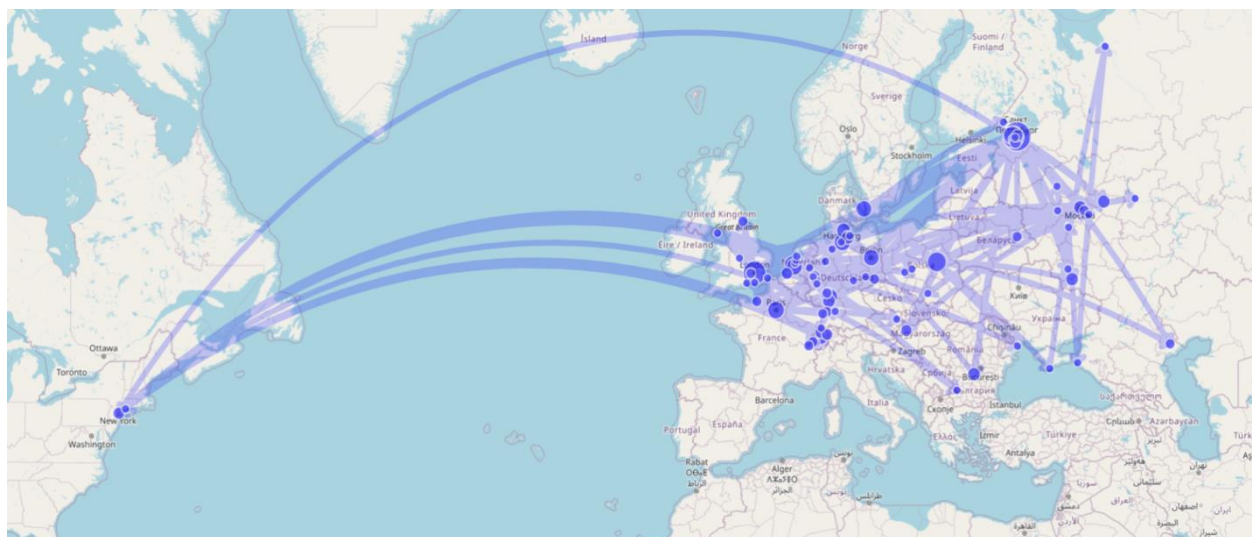


Рис. Топонимы, выявленные в ходе анализа текста дневника

**Эмоции.** Рассматривая количественный анализ маркирующих эмоции слов, мы обнаружили, что главными эмоциями второго тома дневника Ф.П. Литке выступают: радость (75 упоминаний), сюрприз (54 упоминания), грусть (54 упоминания) и беспокойство (38 упоминаний). Близко к этим эмоциям находится гнев (22 упоминания). Интересно то, что «связующими эмоциями» или совместно встречаемыми словами для других эмоций выступают удивление и беспокойство.

Рассматривая сетевые связи эмоций, было обнаружено, что грусть наиболее сильно связана с ключевым словом «здоровье». При этом на графике тенденций четко прослеживается, как коррелирует (противоположные тенденции) между собой упоминания здоровья и чувство радости, которое испытывает Ф.П. Литке: чем чаще в тексте упоминается здоровье, тем более нисходящий тренд у графика, описывающего частоту упоминания словоформы «радость». Очень наглядно это видно в заключительном сегменте второго тома дневника. В этот период упоминание здоровья приобретает минимальные значения, а показатели упоминания радости достигают близких к пиковым, значений. Противоположная картина у графиков упоминания словоформ «здоровье» и «грусть»: они обладают схожей тенденцией и динамикой. Можно сказать, что тема здоровья (себя, близких людей и членов императорской семьи) выступает главным источником в динамике эмоций для Федора Петровича Литке. Этот вывод, полученный с помощью инструментов анализа текста, вполне коррелирует с содержанием дневника.

**Заключение.** В рамках практической работы был проведен практический эксперимент по использованию большой языковой модели для базового интеллектуального анализа рукописного текста. Выделенные с помощью большой языковой модели (LLM) Yandex GPT метаданные для текста дневника Ф.П. Литке позволили с высокой точностью сформировать обобщенные сведения об изучаемом тексте и авторе данного дневника. В целом, обработка метаданных представляет из себя всецело механическую функцию, которая не требует участия исследователя-человека. На конкретном историческом источнике большая языковая модель позволила выявить метаданные из расшифрованного с помощью подготовленной для этого нейронной сети, рукописи Ф.П. Литке. Принципиально такая совместная работа двух нейронных сетей может быть осуществлена «бесшовно» (без участия человека) с помощью применения математических алгоритмов и технических средств.

С помощью технических средств позиционирования данных на карте (специализированный инструмент ресурса «Voyant-tools») была автоматически построена карта, отражающая связи территорий (городов) из дневника Ф.П. Литке, отражающей внимание автора и выстроенную им внутри дневника смысловую связь относительно европейских городов. Принципиально уже сейчас собранный без участия человека пул метаданных с высокой долей вероятности может дать ответы на вопросы о содержании как отдельной рукописи, так и корпуса рукописных документов в целом. При этом полученные метаданные не выступают сведениями, которые интерпретируют исторический источник, а являются расширенным навигатором для исследователя-человека. В рамках исследования сформулирована гипотеза о том, что полученные метаданные позволяют выявить искажения (отклонения) в историческом источнике относительно уже известных сведений. Через этот механизм несоответствия большая языковая модель может «подсвечивать» актуальные исследовательские вопросы для того или иного исторического источника.

## Библиографический список

1. Kropotov D., Lomov N., Stepochkin D., Laptev A. Handwritten Text Recognition and Browsing in Archive of Prisoners' Letters from Smolensk Convict Prison, in: Analysis of Images, Social Networks and Texts 11th International Conference, AIST 2023, Yerevan, Armenia, September 28–30, 2023, Revised Selected Papers. Cham : Springer, 2023. doi P. 227-240.
2. Аракчеев В., Редин Д., Русина Ю. Не объяснить, а понять / Рец. на: Источниковедение : учеб. пособие / И. Н. Данилевский, Д. А. Добровольский, Р. Б. Казаков и др.; отв. ред. М. Ф. Румянцев; Нац. исслед. у-нт «Высш. школа экономики». – М. : Изд. дом Высш. школы экономики, 2015. 685 с. // Quaestio Rossica. №4, 2015. С. 283. <https://doi.org/10.15826/qr.2015.4.138>
3. Manning, Christopher D. Human Language Understanding & Reasoning / Daedalus, № 151 (2), 2022. pp. 127-138.

## INTELLECTUAL ANALYSIS OF F.P. LITKE'S DIARY: LARGE LANGUAGE MODELS AND METADATA IN NATURAL LANGUAGE PROCESSING

*Anton K. Laptev*

HSE University,  
Str. Myasnitskaya, 20, Moscow, Russia, 101000  
[aklaptev@hse.ru](mailto:aklaptev@hse.ru)

The article presents a practical experiment on the use of a large language model based on YandexGPT for the analysis of automatically recognized (using a specially trained model) handwritten text from the diary of Admiral F.P. Litke. Such a "bundle" of neural networks made it possible to obtain valid metadata, which became the basis for thematic modeling of the corpus of manuscripts from the diary of F.P. Litke. As a result, in addition to obtaining a recognized manuscript from the mid-19th century, it was possible to conduct an intelligent analysis of the presented text using ready-made web tools. In practice, this allows us to talk about the possibility of "seamlessly" conducting a full-fledged intelligent analysis of large arrays of manuscripts without dividing this process into separate local iterations.

**Keywords:** neural network technologies, 19th century, intelligent text analysis, natural language processing, large language models.



## РАЗРАБОТКА И ОСОБЕННОСТИ ПРИМЕНЕНИЯ НЕЙРОСЕТЕВОЙ СИСТЕМЫ ДЛЯ ПРОВЕРКИ ОРИГИНАЛЬНОСТИ ТЕКСТА

***Кукса Виталий Константинович***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
prib-211\_126517@volsu.ru

***Поляков Максим Валентинович***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
m.v.polyakov@volsu.ru

В работе рассмотрено применение нейросетевых технологий для определения количества плагиата в тексте. Разработан алгоритм формирования набора данных, выявлены достоинства и недостатки реализованного алгоритма. Спроектирована нейронная сеть на основе полносвязной многослойной архитектуры, обучена с помощью полученной выборки данных и протестирована. Показано, что ошибка в процессе обучения достигает значений менее 10%.

**Ключевые слова:** оригинальность текста, векторизация текста, обучение модели, выявление плагиата, нейронная сеть.

**Введение.** Проблема оценки оригинальности текста и борьбы с плагиатом остается актуальной в современном информационном обществе, где доступ к обширным данным и информации стал более доступным, чем когда-либо. С увеличением объемов написанных текстов, будь то научные работы, студенческие эссе, статьи или документация, возникает необходимость в надежных и эффективных инструментах для проверки оригинальности содержания.

В прошлом, процесс проверки оригинальности текста требовал значительных усилий и времени, и он часто ограничивался ручной проверкой и анализом текстов. Однако с развитием современных информационных технологий и методов программной инженерии, появилась возможность автоматизировать этот процесс с использованием специализированных программных решений.

**Постановка задачи.** Определим, каким образом нейронная сеть будет получать входные данные. На вход ей поступает текст, который необходимо проверить на оригинальность, он будет сравниваться с текстовой базой. Результатом работы нейронной сети является процент оригинальности, где 0 – отсутствие оригинального текста, а 100 – отсутствие плагиата.

Нейронная сеть получает данные в виде тензоров. Тензор – это многомерный массив, который может иметь произвольное число измерений, оно характеризуется рангом тензора, одномерный массив – это тензор 1 ранга. Для преобразования текста в тензор, существует алгоритм векторизации текста [1]. Реализаций данного алгоритма много, однако, самым эффективным решением является использование предобученных моделей для векторизации текста.

Существует достаточно большое количество подобных моделей, но необходимо, чтобы выбранная модель соответствовала следующим требованиям:

1. Модель должна быть обучена на базе русскоязычных текстов.
2. Результат работы модели – вектор фиксированной длины.

Моделью подходящей под данные требования является частью библиотеки `sraCu`. Данная библиотека предоставляет большое количество предобученных моделей на разных языках и в том числе русском, кроме того результатом работы `sraCu` является вектор с фиксированной длиной равной 96, благодаря этому нет необходимости самим выделять определенные признаки текста, приводить вектор к фиксированной длине, ведь сказалось бы на производительности формирования набора данных.

### **Проектирование и обучение нейронной сети, формирование Dataset.**

В качестве архитектуры нейронной сети была выбрана многослойная нейронная сеть [2]. Данная архитектура является универсальной и подходит под большое количество задач. Количество нейронов на входном слое определяется размером вектора текста, который в нашем случае равен 96, на выходе будет один нейрон, в котором будет полученный процент оригинальности текста. Подход к выбору количества скрытых слоев и нейронов в каждом из них не имеет четких правил, и определяется эмпирически. В начальной стадии экспериментов было принято решение использовать один скрытый слой, количество нейронов в котором определяется как среднее арифметическое между количеством нейронов во входном и выходном слоях.

Обучение нейронной сети проводилось с «учителем» [3], то есть мы указываем нейронной сети, какой должен быть результат, а она корректирует веса в связях между нейронами, чтобы этот результат получить. Для обучения нейронной сети распознаванию плагиата, необходим большой набор данных, он будет состоять из 3 частей:

- 1.База текстов.
- 2.Обучающая выборка.
- 3.Тестовая выборка.

В качестве базы использовались статьи с ресурса `Cyberleninka`, для формирования этой базы был реализован парсер. Весь набор данных формируется во время парсинга статей, тексты обрабатываются группами по 25 элементов, где первые 24 элемента фрагмент будущей базы, а последний элемент – фрагмент обучающей выборки [4]. Схема формирования набора представлена на схеме (рис. 1).

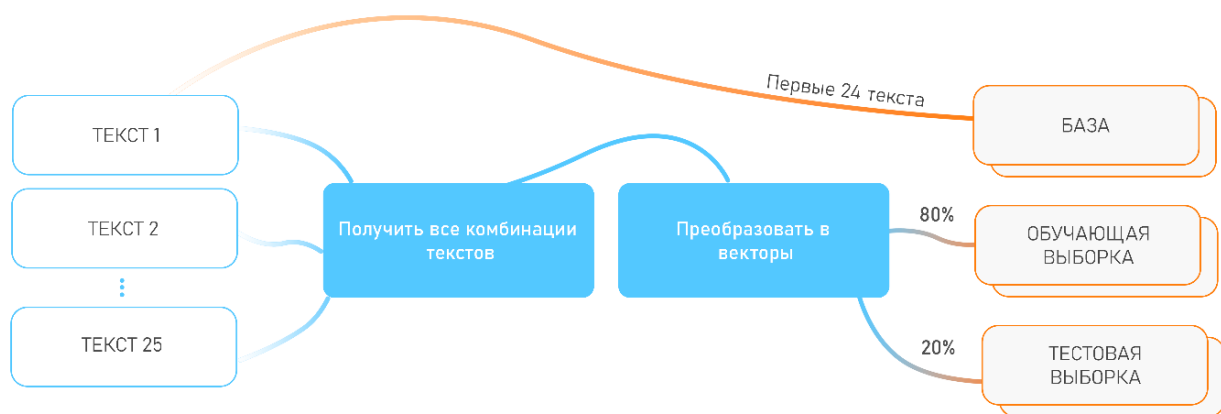


Рис. 1. Схема формирования набора данных для нейронной сети

**Тестирование нейронной сети.** Для тестирования эффективности разработанной нейросетевой модели была проведена обработка 3000 статей. Хотя объем данных может быть рассмотрен как относительно небольшой, он все же достаточен для извлечения значимых выводов о работе нейронной сети.

График на рис. 2 отображает зависимость ошибки от числа эпох обучения.




Рис. 2. Зависимость ошибки от эпохи обучения нейронной сети

Анализ этого графика позволяет оценить скорость сходимости модели: с увеличением числа эпох ошибка снижается, что указывает на эффективное обучение нейронной сети в процессе итераций обучения.

В табл. представлены результаты тестирования обученной нейронной сети.

Таблица

#### Результаты тестирования нейросетевой модели

Метрика	Значение
MAE	11.38
MSE	174.22
R2	0.71

**Заключение.** На основании данных, полученных из R2-метрики [5], можно сделать вывод, что модель довольно успешно решает задачу регрессии. Однако наблюдается высокая ошибка в определении плагиата. Исходя из результатов тестирования, выявлено, что увеличение объема обучающей выборки приведет к увеличению итоговой точности модели.

### **Библиографический список**

1. Manning C. D., Schiitze H. Foundations of Statistical Natural Language Processing. – 2nd. – London, England : Massachusetts Institute of Technology, 1999. – P. 620.
2. Vang-Mata R. Multilayer Perceptrons: Theory and Applications. – Nova Science Publishers, 2020. – P. 143.
3. Шолле Ф. Глубокое обучение на Python. 2-е международное издание. –Санкт-Петербург : Питер, 2023. – С. 576.
4. Kuksa V., Polyakov M. Developing and Applying a Neural Network System for Text Plagiarism Detection in Higher Education // Proceedings – 2024 4th International Conference on Technology Enhanced Learning in Higher Education, TELE 2024, 2024, pp. 412–416
5. C, Muller Andreas and Guido, Sarah. Introduction to machine learning with python. – O'Reilly Media, 2016.

## **DEVELOPMENT AND APPLICATION OF NEURAL NETWORK SYSTEM FOR TEXT ORIGINALITY VERIFICATION**

***Kuksa Vitaliy Konstantinovich***

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
prib-211\_126517@volsu.ru

***Polyakov Maxim Valentinovich***

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
m.v.polyakov@volsu.ru

The article considers the application of neural network technologies to determine the degree of plagiarism in the text. The algorithm of data set formation is developed, advantages and disadvantages of the realized algorithm are revealed. A neural network based on a fully-connected multilayer architecture is designed, trained using the obtained data sample and tested. It is shown that the error in the training process reaches values less than 10 percents.

**Keywords:** text originality, text vectorization, model training, plagiarism detection, neural network.

## **АИ И ЛИНГВИСТИЧЕСКАЯ ИДЕНТИЧНОСТЬ: КАК ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ВЛИЯЕТ НА ЯЗЫКОВУЮ КУЛЬТУРУ И РАЗНООБРАЗИЕ**

***Москвитина Анастасия Михайловна***

Балтийский государственный технический университет «ВОЕНМЕХ»  
им. Д.Ф. Устинова,  
190005, Россия, г. Санкт-Петербург, ул. 1-я Красноармейская, д. 1  
moskvitina.anastasia@internet.ru

***Москвитин Валерий Александрович***

Балтийский государственный технический университет «ВОЕНМЕХ»  
им. Д.Ф. Устинова,  
190005, Россия, г. Санкт-Петербург, ул. 1-я Красноармейская, д. 1  
moskvitin\_va@voenmeh.ru

В статье рассматривается влияние искусственного интеллекта на языковую культуру и идентичность. Анализируется, как технологии машинного перевода и автоматического распознавания речи изменяют способы взаимодействия людей с языками и культурами. Особое внимание уделяется малоресурсным языкам, для которых ограниченные обучающие данные создают трудности в разработке эффективных систем перевода и распознавания.

**Ключевые слова:** малоресурсные языки, искусственный интеллект, языковая идентичность, машинное обучение, обработка естественного языка, автоматическое распознавание речи, речевые технологии, лингвистическое моделирование.

**Введение.** В последние годы влияние искусственного интеллекта (artificial intelligence, AI) на язык и культуру значительно возросло. Такие технологии как машинный перевод, системы автоматического распознавания и синтеза речи подвергают трансформации способы взаимодействия людей с языками и другими культурами. Понимание того, как искусственный интеллект влияет на языковую идентичность в целом, представляет собой ключевой аспект для оценки влияния технологий на культурные и языковые процессы. Извлечение максимального потенциала из данных технологий для сохранения культурного наследия становится все более значимой составляющей.

Малоресурсные языки (under-resourced languages) вызывают большой научный интерес со стороны лингвистического сообщества. Ограниченный объём обучающих данных представляет собой препятствие для развития средств автоматического распознавания речи для данных языков. В последнее время изучаются и разрабатываются новые технологии для эффективного исследования и сохранения малоресурсных языков. Среди современных методов лингвистического анализа малоресурсных языков выделяют методы машинного обучения, компьютерной лингвистики, краудсорсинга, нейронные сети и другие инновационные подходы.

Малоресурсные языки представляют собой языки без электронных корпусов. Для таких языков существует ограниченное количество письменных и устных ресурсов. В компьютерной лингвистике данные языки получили назва-

ние «малоресурсные» – под «ресурсом» понимаются тексты в цифровой форме, которые необходимы для обучения компьютерных моделей [1].

С одной стороны, автоматический перевод и различные голосовые помощники способствуют отчасти унификации и стандартизации языков. Данная тенденция влечет за собой такое последствие, как уменьшение использования и поддержки менее распространенных языков (малоресурсных языков), что может разрушить уникальные культурные черты и особенности. А некоторые языки могут даже оказаться под угрозой исчезновения, поскольку их носители могут предпочесть использование языков, поддерживаемых технологиями искусственного интеллекта.

С другой стороны, AI имеет потенциал для поддержки и сохранения языкового разнообразия. Разработка специализированных приложений для изучения и использования малоресурсных языков, а также создание цифровых словарей, корпусов и систем автоматизированного перевода может способствовать их сохранению.

#### Проблемы перевода малоресурсных языков

В настоящее время лишь 20 языков (из порядка 7000) хорошо подготовлены для работы с нейронными сетями [2]. Лучше всего обработаны западноевропейские языки, китайский язык и японский язык. Так как для данных языков существует большое количество описанных слов, наличие текстов различных жанров, словарей, тезаурусов и т.п. Языки без письменности практически невозможно обработать, потому что лингвистические ресурсы – это основа для разработки систем перевода. Для многих африканских и азиатских языков, для вымирающих языков и местных диалектов отсутствуют какие-либо ресурсы. Это касается не только параллельных корпусов, но и молилингвальных корпусов.

Для малоресурсных языков не развиты речевые технологии. А значит использование в современных информационных системах затруднено. Более того, существует тенденция вытеснения малоресурсных языков ведущими мировыми языками [1].

Попытки создания универсальных систем перевода усложняются диалектной вариативностью малоресурсных языков.

#### Причины оцифровывания малоресурсных языков

1. Сохранение культурного наследия малоресурсных языков для поддержания языкового разнообразия в мире. Обработка естественного языка документирует языки и создает систему для языков без письменности [3].

2. Анализ демографических и политических процессов. Создание электронных корпусов для малоресурсных языков позволяет носителям активно участвовать в цифровом мире, общаться с другими людьми, а также получать доступ к информации и услугам.

3. Помощь при чрезвычайных ситуациях, важных событий мирового масштаба. Носители малоресурсных языков не способны выстроить коммуникацию с иностранными спасателями, врачами. Для подобных случаев переводчиков не хватает. Такие инновационные технологии, как машинный перевод, автоматическое распознавание речи упростили и ускорили процесс коммуникации в экстренных ситуациях [1].

#### Современные методы лингвистического анализа малоресурсных языков

### 1. Машинное обучение и модели на основе нейронных сетей.

Разработка и использование нейронных сетей (например, моделей типа Transformer) стало прорывом в машинном переводе. Даже с ограниченным количеством ресурса данные модели способны эффективно переводить тексты. Это достигается за счет предварительного обучения на больших по объёму мультилингвальных корпусах и последующего дообучения на данных малоресурсных языков [4].

Сейчас модели предобучения, например, такие как BERT и GPT, могут адаптироваться к конкретным языкам с использованием даже небольшого объёма данных.

### 2. Переносное обучение.

Техника переноса обучения (Transfer learning) стала активно применяться в области обработки естественного языка. Такой подход позволяет использовать обучение (или знания) между текстами на разных языках при работе с текстовыми данными малого объёма [4].

В данном случае используют такую модель как fine-tuning, которая позволяет улучшить предварительно обученную модель на данных малоресурсных языков [5].

### 3. Компьютерная лингвистика и автоматический анализ текста.

Важную роль в обработке малоресурсных языков играют такие инструменты компьютерной лингвистики как парсеры и анализаторы текстов. Вместе с алгоритмами машинного обучения их можно адаптировать для работы с малым объёмом данных.

Например, можно проводить автоматический морфологический анализ текстов на основе уже существующих лингвистических теорий и практик. А также можно разрабатывать формальные грамматики для малоресурсных языков на основе собранной информации [6].

### 4. Краудсорсинг.

Краудсорсинг (crowdsourcing) становится всё более популярным методом сбора информации для создания лингвистических ресурсов для малоресурсных языков. Данный метод берёт в свою основу активное взаимодействие с носителями языка, которые в процессе работы помогают собирать, обрабатывать, аннотировать и верифицировать данные [7]. Данный метод помогает собирать ценный аудиоматериал, который в дальнейшем будет использоваться для тренировки моделей автоматического распознавания речи [6].

Ярким примером использования данного метода является якутский язык. Энтузиасты по сохранению языка обратились в компанию Яндекс с целью создания цифрового корпуса. Именно так был создан первый обучающий набор для якутского языка в размере 100 тысяч пар параллельных предложений (русский-якутский) [1].

Таким образом, малоресурсные языки представляют собой довольно сложную область для исследования. Благодаря современным технологиям искусственного интеллекта и лингвистического анализа открываются новые возможности для сохранения и развития языкового разнообразия. Будущее малоресурсных языков во многом зависит от интеграции инновационных методов и активного участия языкового сообщества с лингвистами.

## Библиографический список

1. Карпов, А. А., Верходанова В.О. Речевые технологии для малоресурсных языков мира // Вопросы языкознания. – 2015. – № 2. – С. 117-135.
2. Копотев М. В. Введение в корпусную лингвистику: Учебное пособие для студентов филологических и лингвистических специальностей [Электронный ресурс]. Прага, 2014. – 230 с.
3. Лобанов Б. М., Елисеева О. Е. Речевой интерфейс интеллектуальных систем. Учебное пособие. – Минск: БГУИР, 2006. – 152 с.
4. Маслечкина С. В. Выражение эмоций в языке и речи // Вестник Брянского государственного университета. – 2015. – № 3. – С. 231-236.
5. Мурадова А. Р. Как исчезают языки и как их возрождают. Языковое разнообразие в кибберпространстве: российский и зарубежный опыт. – М.: МЦБС, 2008. – 218 с.
6. Николаева И. С., Митрениной О. В., Ландо Т. М. Прикладная и компьютерная лингвистика. – М.: URSS, 2016. – 320 с.
7. Обработка естественного языка, распознавание и синтез речи // Альманах «Искусственный интеллект». – МФТИ, 2019. – 180 с.
8. Плунгян В. А. Почему языки такие разные. – М.: АСТ-ПРЕСС КНИГА, 2010. – 272 с.
9. Тампель И. Б., Карпов А. А. Автоматическое распознавание речи. Учебное пособие. – СПб: Университет ИТМО, 2016. – 138 с.
10. Толмачев С.Г. Основы искусственного интеллекта: учебное пособие. СПб.: ЮГТУ «Военмех», 2017. – 132 с.
11. Besacier L., Barnard E., Karpov A., Schultz T. Automatic speech recognition for under-resourced languages: A survey // Speech communication – 2014. Vol. 56. P. 85-100.
12. Hosna, Asmaul, Merry, Ethel, Gyalmo, Jigme, Alom, Zulfikar. Transfer learning: a friendly introduction // Journal of Big Data. – 2022. – №9 – P. 1-19.
13. Howard J. и Ruder S. Universal Language Model Fine-tuning for Text Classification // Journal Computing Research Repository. – 2018. – №5 – P. 6-10.
14. Jianhua T., Tieniu T. Affective Computing: A Review // Conference: Affective Computing and Intelligent Interaction, First International Conference. – Beijing: 2005. – P. 981-995.
15. Parent G., Eskenazi M. Toward better crowdsourced transcription: transcription of a year of the Let's Go bus information system data. Proc. IEEE workshop on spoken language technology SLT-2010 – Berkeley, USA – 2010. Vol. 43 – P. 312-317.

## LINGUISTIC IDENTITY: HOW ARTIFICIAL INTELLIGENCE AFFECTS LANGUAGE CULTURE AND DIVERSITY

***Moskvitina Anastasia Mikhailovna***

Baltic State Technical University "VOENMEH" named after D.F. Ustinov,  
Str. Krasnoarmeyskaya, 1, St. Petersburg, Russia, 190005  
moskvitina.anastasia@internet.ru

***Moskvitin Valerii Alexandrovich***

Baltic State Technical University "VOENMEH" named after D.F. Ustinov,  
Str. Krasnoarmeyskaya, 1, St. Petersburg, Russia, 190005  
moskvitin\_va@voenmeh.ru

The article examines the impact of artificial intelligence on language culture and identity. It analyzes how machine translation technologies and automatic speech recognition are changing the ways people interact with languages and cultures. Special attention is paid to low-resource languages, for which limited training data create difficulties in developing effective translation and recognition systems.

**Keywords:** low-resource languages, artificial intelligence, linguistic identity, machine learning, natural language processing, automatic speech recognition, speech technologies, linguistic modeling.



## АВТОМАТИЗАЦИЯ ПОВЫШЕНИЯ КАЧЕСТВА РАБОТЫ НЕЙРОСЕТЕВОЙ МОДЕЛИ

*Неверов Антон Робертович*

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
antonneverov.astrohaker@gmail.com

В статье приведены результаты исследования по автоматизации алгоритма поиска наиболее успешного варианта применения обученной нейросетевой модели. Описаны несколько алгоритмов оценки нейросетевой модели, применяемых на практике, достоинства и недостатки каждого из них. Приведен способ автоматизации одного из алгоритмов.

**Ключевые слова:** искусственный интеллект, нейросетевые технологии, оценка качества модели.

**Введение.** При работе с нейросетевыми моделями, возникает вопрос оценки качества обучения модели.

В ходе исследования данного вопроса были проанализированы работы [1-4]. Независимо от того, каким вопросом занимались авторы исследования: детектирование с помощью нейронных сетей изображений, звука или работа со статистическими данными, качество обучения нейронной сети основывается на таких базовых понятиях как количество успешных или количество ложных детектирований.

В данной работе рассмотрен вопрос о возможных вариантах повышения качества работы уже обученной нейросети путем применения алгоритма тестирования с автоматическим подбором гиперпараметра, суть которого раскрыта в основной части.

**Основная часть.** Пусть дана уже обученная на различных звуках нейронная сеть, которая умеет распознавать  $X$  ключевых слов из аудиопотока,  $X > 2$ .

Отправляя аудиофрагмент на распознавание такой нейросети, мы будем получать от нее некоторый вектор  $Y = \{X_1, X_2, \dots\}$ , каждый компонент которого будет вероятностью совпадения аудиофрагмента с каждым из ключевых слов, на которых была обучена нейросеть. Зафиксируем, что  $X_1$  это наиболее интересующее нас ключевое слово и необходимо понять, присутствует ли оно в аудиофрагменте или нет.

На данном этапе начинает возникать вопрос: какая должна быть вероятность  $X_1$ , чтобы слово считать ключевым? Это некоторый гиперпараметр задаваемый человеком, назовем его порогом вероятности, и пусть для начала его значение равно 0.5. Если значение вероятности  $X_1$  больше или равно значению порога вероятности, то значит нейросеть определила слово как ключевое.

Тогда не составляет сложности разбить некоторый тестовый аудиофайл на аудиофрагменты и посчитать количество ложных и успешных срабатываний.

Такая работа может быть проделана в автоматическом режиме, не требуя участия человека, но возникает следующая проблема №1: каким образом можно сравнить две нейросетевые модели? Допустим у одной из них 32 положительных срабатывания и 46 ложных, а у другой 35 положительных и 47 ложных. Как понять, какую из нейросетей считать лучше обученной? И проблема №2: если в другом компоненте вектора  $X$  есть значение с той же или большей вероятностью, чем  $X_1$ , считать ли  $X_1$  ключевым словом, несмотря на достижение им порога вероятности?

Начнем с проблемы №2. При разных настройках обучения сети вероятности компонент вектора  $X$  будут сильно отличаться от модели к модели, поэтому сделать привязку на их соотношение друг с другом невозможно, но можно рассматривать порог вероятности как гиперпараметр, задаваемый человеком и, как следствие, был разработан следующий алгоритм:

1. Просматривая компоненты вектора, фиксируем, что  $X_1$  самый большой по абсолютному значению. Если это не так, ключевого слова в аудиофрагменте нет.

2. Вероятность  $X_1$  должна быть больше, чем порог вероятностей, тогда ключевое слово будет считаться обнаруженным, в противном случае его также нет.

Данный алгоритм позволил снизить ложные активации на 70%, убрав вариант, при котором вероятность  $X_1$  была больше, чем порог вероятностей, но при этом в векторе были компоненты, значения которых были не меньше, чем  $X_1$ , что приводило к ложным срабатываниям.

Переходим к проблеме №1.

Чтобы не запутаться в количестве ложных и успешных срабатываний, необходимы другие способы сравнения моделей. Часто на практике применяют точность и полноту [5]. Однако от одних двух показателей качества модели переходим к другим двум показателям и сравнивать по-прежнему неудобно, необходимо одно, некоторое числовое значение. Таким единым параметром может выступить F-мера [6]. Чем ближе F-мера к значению 1.0, тем лучше обучена модель. F-мера основывается на показателях точности и полноты модели, в то время как они, в свою очередь, основываются на значениях количества успешных и ложных срабатываний. Но что определяет количество таких срабатываний? Порог вероятностей, задаваемых человеком, при другом пороге значения будут другие, соответственно и другая будет F-мера модели. Кроме того, порог вероятностей участвует в алгоритме решения проблемы №2.

Возникает следующий закономерный вопрос: каким же образом можно задать этот порог так, чтобы модель показала лучшую F-меру? В ходе исследования этой проблемы оказалось, что решение может быть найдено, если идти в обратную сторону. И звучит это так: какой порог должен быть, если нам задано лучшее значение F-меры? Для этого модель тестируется на аудиофайле с разными порогами вероятностей полным перебором от 0 до 1 с шагом 0.05. Найдя лучшее значение F-меры, значение порога вероятности нам также будет известно и возможно его применение в алгоритме проблемы №2.

В рамках исследования описанной ранее проблемы были записаны тестовые аудиофайлы: с произношением ключевого слова в количестве 385 раз, а также двухчасовой аудиофайл с бытовыми шумами: тишина, работа кондицио-

нера, звуки машин на улице. Кроме того, позже был записан третий аудиофайл, содержащий произношения человеком других слов, кроме ключевого. Обучив нейросетевую модель, было решено посмотреть, как она распознает произношение ключевого слова, а также нет ли ложных активаций на этих тестовых аудиофайлах.

На рис. 1 представлена зависимость количества успешных срабатываний на аудиофайле, содержащем произнесенные ключевые слова, от порога вероятности:




Рис. 1. Зависимость успешных срабатываний от порога вероятности

Из построенного графика можно сделать вывод о том, что значение порога вероятности до 0.5 включительно не оказывает влияния на процент распознавания, что косвенно говорит о том, что модель обучена достаточно хорошо. После 0.8 процент распознавания начинает быстро падать.

Посмотрим на качество обучения с другой стороны, сделав попытку распознавания на двух других аудиофайлах и выявив таким образом количество ложных, представим график на рис. 2.

Из представленного выше рисунка можно сделать вывод, что порог вероятности от 0 до 0.5 включительно не оказывает влияния на работу нейросетевой модели, однако уже после 0.55 количество ложных срабатываний начинает резко сокращаться.

Совместив два графика на одном, мы увидим картину, представленную на рис. 3.

Аналогичным образом стоит построить график F-меры и рассмотреть зависимость ее значений от выбранного порога вероятности, график представлен на рис. 4.

Следуя выводам, полученных из графиков на рис. 1 и 2, следовало, что F-мера также будет оставаться постоянной при пороге вероятностей от 0 до 0.5. По мере увеличения значения порога вероятности она начинает снижаться, с

исключением на значении порога 0.6: там F-мера почти достигает прежнего лучшего значения.




Рис. 2. Зависимость ложных срабатываний от порога вероятности




Рис. 3. График положительных и ложных срабатываний

Стоит еще раз подчеркнуть, что описанные выводы относятся только к равновзвешенной F-мере. Однако применяя данный подход к моделям из реальных задач, порой стоит отдать приоритет ложным срабатываниям. С точки зрения пользователя понижение количества ложных срабатываний в 2 раза намного больше повышает пользовательский опыт чем падение успешных распознаваний с 270 до 240, например. В этом случае формула F-меры будет иной.




Рис. 4. Зависимость F-меры от порога вероятности

**Заключение.** В результате проведения данного исследования было показано, каким образом, не переобучая нейросетевую модель можно снизить количество ложных срабатываний, не повышая существенно количество нераспознанных ключевых слов, увеличивая значение F-меры. Разобран способ автоматического тестирования и сравнения моделей между собой. Показан способ автоматического подбора гиперпараметра, отвечающего за качество применения модели.

### Библиографический список

1. Cao, Van Loi & Le-Khac, Nhien-An & O'Neill, Michael & Nicolau, Miguel & Mcdermott, James. (2016). Improving Fitness Functions in Genetic Programming for Classification on Unbalanced Credit Card Data.
2. Khan, Asifullah & Saeed, Aqsa & Wahab, Noor & Hussain, Mutawara & Hamza, Muhammad. (2019). A Recent Survey on the Applications of Genetic Programming in Image Processing
3. Yordi, Estela & Koelig Romero, Raúl & Matos, Maria & Perez, Amaury & Caballero, Yailé & Santana, Lourdes & Quintana, Manuel & Molina Pérez, Enrique & Uriarte, Eugenio. (2019). Artificial Intelligence Applied to Flavonoid Data in Food Matrices. *Foods*. 8. 573. 10.3390/foods8110573.
4. Carrara, Fabio & Falchi, Fabrizio & Caldelli, Roberto & Amato, Giuseppe & Becarelli, Rudy. (2019). Adversarial image detection in deep neural networks. *Multimedia Tools and Applications*. 78. 10.1007/s11042-018-5853-4.
5. Juba, Brendan & Le, Hai. (2019). Precision-Recall versus Accuracy and the Role of Large Data Sets. *Proceedings of the AAAI Conference on Artificial Intelligence*. 33. 4039-4048. 10.1609/aaai.v33i01.33014039.
6. Sasaki, Yutaka. (2007). The truth of the F-measure. *Teach Tutor Mater*.

# NEURAL NETWORK SYSTEM FOR PREDICTING THE VALUE OF REAL ESTATE IN THE PRIMARY HOUSING MARKET

*Anton R. Neverov*

Perm State National Research University,  
Str. Bukireva, 15, Perm, Russia, 614068  
antonneverov.astrohaker@gmail.com

The article presents the results of a study on automating the search algorithm for the most successful application of a trained neural network model. Several algorithms for evaluating a neural network model used in practice are described, along with the advantages and disadvantages of each of them. A method for automating one of the algorithms is presented.

**Keywords:** artificial intelligence, neural network technologies, model quality assessment.

УДК 004.891.2

## ИССЛЕДОВАНИЕ МЕТОДОВ ИЗВЛЕЧЕНИЯ ИНДИВИДУАЛЬНЫХ ПРИЗНАКОВ ЭМОЦИОНАЛЬНОЙ ОКРАСКИ ИЗ КОЛЛЕКЦИИ ПОЛЬЗОВАТЕЛЬСКИХ ТЕКСТОВ

*Ивутин Алексей Николаевич,*

alexey.ivutin@gmail.com

*Савенков Павел Анатольевич*

pavel@savenkov.net

*Волошко Анна Геннадьевна*

a.g.troshina@gmail.com

*Крюков Олег Сергеевич*

ol\_kryukov97@mail.ru

ФГБОУ ВО «Тульский государственный университет»,  
300012, Россия, г. Тула, пр-кт Ленина д.92

В статье представлено исследование методов извлечения индивидуальных признаков эмоционального окраса из наборов пользовательских текстов с применением бинарной классификации. Осуществлена сравнительная характеристика методов на базе различных архитектур, таких как полносвязные нейронные сети, рекуррентные нейронные сети (RNN), сети с долговременной и кратковременной памятью (LSTM) и механизма управления вентелей в сетях GRU на применимость в задаче анализа эмоционального окраса наборов пользовательских текстов. Показано, что наиболее рациональным выбором являются рекуррентные сети LSTM и GRU.

**Ключевые слова:** анализ эмоционального окраса, машинное обучение, бинарная классификация, нейронные сети.

**Введение.** В настоящее время использование инструментов анализа индивидуальных признаков, идентифицирующих человека, его активность, становится все более актуальным в различных областях [1-2]. Под термином индиви-

дуальные признаки понимается набор данных, описывающий определенные действия или активность человека, или же различные явления [3].

Для извлечения индивидуальных признаков из наборов пользовательских текстов, а именно получения количества позитивно и негативно окрашенных текстов в данной статье осуществляется выбор наиболее рациональной структуры нейронной сети. Далее в работе будут рассмотрены различные архитектуры нейронных сетей.

**Исследование структур нейронных сетей для анализа эмоционального окраса.** Для обучения нейронных сетей, а именно бинарного классификатора, был использован крупнейший набор RuTweetCorp – открытый корпус текстов, собранный автоматически из русскоязычного Twitter с ручным фильтрованием.

Для бинарной классификации эмоционального окраса была использована полносвязная модель типа Sequential, где все слои связаны последовательно от входного до выходного слоя. Графическое представление сети представлено на рис. 1.

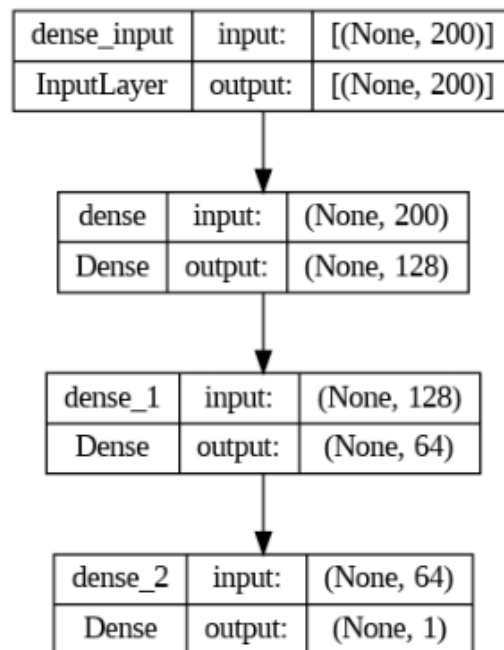


Рис. 1. Графическое представление полносвязной модели нейронной сети типа Sequential

Вместо представления слова одним числом, было использовано векторное представление типа One Hot Encoding [4]. Архитектура сети представлена на рис. 2.

Также, для формирования более полной картины работы методов извлечения признаков, используем представление входных данных текстов в виде плотных векторных представлений Embedding [5] (рис. 3).

Для повышения качества работы сети возможно использовать рекуррентную, а не полносвязную нейронную сеть. При ее использовании возможно повышение качество работы метода, связанное с учетом последовательности слов во входных пользовательских текстах. Дополним нейронную сеть дополни-

тельным рекуррентным слоем SimpleRnn [6], который содержит 8 нейронов (рис. 4).

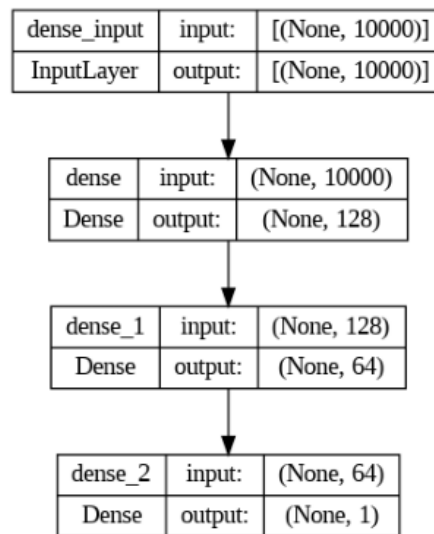


Рис. 2. Графическое представление полносвязной модели нейронной сети с кодированием OneHotEncoding

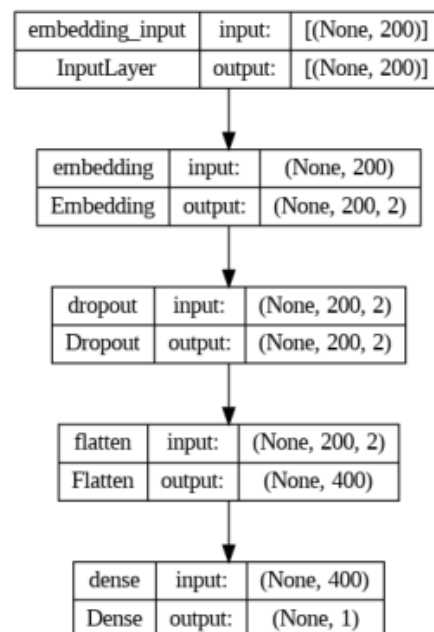


Рис. 3. Графическое представление полносвязной модели нейронной сети с кодированием Embedding

Также, слой SimpleRnn был заменен на LSTM и GRU. Сформируем нейронную сеть, содержащую слой LSTM (рис. 5) и GRU [7] (рис. 6).

В результате экспериментального исследования получена сравнительная характеристика работы нейросетей с различной структурой для анализа эмоционального окраса и представлена в таблице.



**Заключение.** В результате проводимого исследования, установлено, что при использовании полносвязной нейронной сети с применением числового кодирования для анализа эмоционального окраса текстов, наблюдается ограничение в достижении значимых результатов, не превышающих 51%, что не позволяет использовать данную архитектуру для извлечения персонализированных признаков эмоционального окраса.

Более высокие показатели были зафиксированы при использовании векторных методов представления текстов, таких как One Hot Encoding и Embedding. При использовании One Hot Encoding, качество работы составило 82%, а при использовании Embedding 86% на проверочном наборе данных.

При изменении архитектуры нейронной сети и добавлении рекуррентных слоев, а именно простой рекуррентный слой, качество работы сети составило при использовании слоя SimpleRnn 79%, при добавлении слоя LSTM 84%, а при изменении его на GRU 87%.

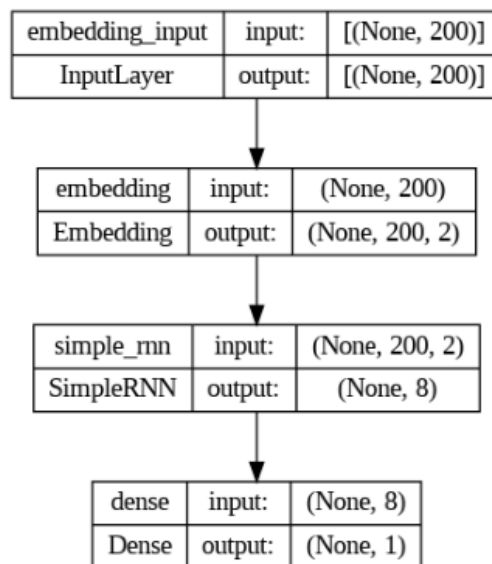


Рис. 4. Рекуррентная нейронная сеть

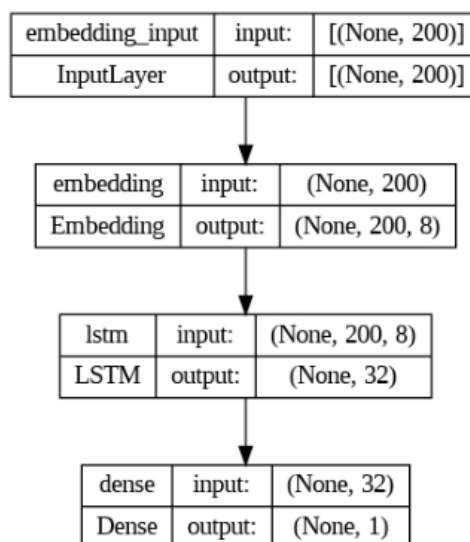


Рис. 5. Нейронная сеть со слоем LSTM

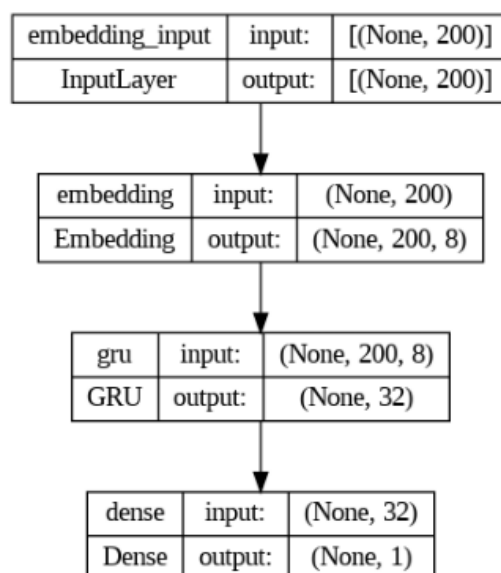


Рис. 6. Нейронная сеть с слоем GRU

Таблица

### Сравнительная характеристика работы нейронных сетей

	Полносвязная			Рекуррентная		
	Числовое кодирование	OneHotEncoding	Embedding	Рекуррентная Embedding	LSTM	GRU
Доля верных ответов на обучающем наборе	55,17%	82%	86%	79%	84%	87%

Использование наборов пользовательских текстов, как источника поведенческой информации на мобильных устройствах, открывает новые возможности для более глубокого понимания потребностей сотрудников и повышения эффективности бизнес-процессов.

**Поддержка исследования.** Исследование выполнено за счет гранта Российского научного фонда № 24-21-20022, <https://rscf.ru/project/24-21-20022/> и комитета Тульской области по науке и инноватике

### Библиографический список

1. Лебеденко Ю. И. Биометрические системы безопасности. – Directmedia, 2013.
2. Гаврильченко Ю. П. Применение биометрических технологий при идентификации и аутентификации субъекта финансовых правоотношений //Бизнес, менеджмент и право. – 2021. – №. 2. – С. 20-27.
3. Гунько Н. Е. Биометрические признаки почерка для обеспечения информационной безопасности //Безопасность информационных технологий. – 2010. – Т. 17. – №. 1. – С. 64-65.
4. Seger C. An investigation of categorical variable encoding techniques in machine learning: binary versus one-hot and feature hashing. – 2018.
5. Li Y., Yang T. Word embedding for understanding natural language: a survey //Guide to big data applications. – 2018. – С. 83-104.
6. Alharbi N. M. et al. Evaluation of sentiment analysis via word embedding and RNN variants for Amazon online reviews //Mathematical Problems in Engineering. – 2021. – Т. 2021. – №. 1. – С. 5536560.

7. Shewalkar A., Nyavanandi D., Ludwig S. A. Performance evaluation of deep neural networks applied to speech recognition: RNN, LSTM and GRU //Journal of Artificial Intelligence and Soft Computing Research. – 2019. – T. 9. – №. 4. – C. 235-245.

## **STUDY OF METHODS FOR EXTRACTING INDIVIDUAL FEATURES OF EMOTIONAL COLORING FROM A COLLECTION OF USER TEXTS**

***Alexey N. Ivutin***

Tula State University,  
300012, Russia, Tula, Prospect Lenina, 92  
alexey.ivutin@gmail.com

***Pavel A. Savenkov***

Tula State University,  
300012, Russia, Tula, Prospect Lenina, 92  
pavel@savenkov.net

***Anna G. Voloshko***

Tula State University,  
300012, Russia, Tula, Prospect Lenina, 92  
a.g.troshina@gmail.com

***Oleg S. Kryukov***

HSE University,  
Tula State University,  
300012, Russia, Tula, Prospect Lenina, 92  
ol\_kryukov97@mail.ru

The article presents a study of methods for extracting individual features of emotional coloring from sets of user texts using binary classification. A comparative characteristic of methods based on various architectures, such as fully connected neural networks, recurrent neural networks (RNN), networks with long-term and short-term memory (LSTM) and the mechanism of gate control in GRU networks, is carried out for applicability to the task of analyzing the emotional coloring of sets of user texts. It is shown that the most rational choice is the recurrent LSTM and GRU networks. The study was supported by the grant of the Russian Science Foundation No. 24-21-20022, <https://rscf.ru/en/project/24-21-20022/> and the Tula Region Committee on Science and Innovation.

**Keywords:** emotional coloring analysis, machine learning, binary classification, neural networks.

## ОБ ОДНОМ ПОДХОДЕ К ИНТЕЛЛЕКТУАЛЬНОМУ АНАЛИЗУ ТЕКСТОВ

*Шпирко Сергей Валерьевич*

Российский государственный гуманитарный университет,  
Отделение интеллектуальных систем в гуманитарной сфере,  
119313, Россия, г. Москва, Ленинский пр-т, 88-3-122  
shpirkos@mail.ru

В статье представлено описание концепции интеллектуального комплекса текстологического моделирования, его структуры и функций. Авторский программный комплекс позволяет с заданной степенью нечеткости решать задачи текстологической классификации. В статье раскрываются концептуальные основы анализа текстов на основе методологии нечеткого распознавания текстов. Рассматриваемый комплекс интеллектуального текстологического моделирования был апробирован для анализа ряда древнерусских текстов.

**Ключевые слова:** модель нечеткого распознавания, компьютерная текстология, стемма, алгоритмы множественного выравнивания, коллекция текстов, нечеткая генеалогическая классификация

**Введение.** Текст средневекового произведения в процессе своего исторического бытования подвергался различным изменениям и искажениям. Классификация его сохранившихся копий (списков) для восстановления оригинального текста является необходимым условием всякого текстологического исследования. В последнее время, одним из важных направлений фундаментальных научных исследований в области анализа текстов стало формирование компьютерной текстологии.

Практика создания и развития больших языковых моделей показывает смещение фокуса внимания от задач анализа и обработки изменений в коллекциях текстов ко все более глубокому познанию сущностных задач исторической текстологии. Так, одним из важных новых направлений исследований в текстологии является разработка и апробация методов искусственного интеллекта в данной сфере. В этой связи можно отметить существенные достижения в рамках научных школ МГУ, ФИЦ «Информатика и управление» (Москва), РГГУ, СПбГУ, Ин-та русского языка им. В.В. Виноградова, Ижевского гос. тех. ун-та, Пермского гос. ун-та, РАНХиГС и др. [1-7].

**Метод нечеткой генеалогической классификации.** В основании предложенного подхода лежит осознание нечеткости, неоднозначности как универсальной реальности человеческой деятельности, в частности, процесса копирования средневековых текстов. Так, о принадлежности списка той или иной текстually близкой группе можно говорить лишь с определенной долей достоверности.

Для учета этой неоднозначности весьма перспективной представляется идея привлечения идей и методов теории нечетких множеств. Разработанный автором алгоритм использует такие стандартные понятия теории нечетких

множеств как функция принадлежности, класс эквивалентности и порядка, имеющие естественную интерпретацию на профессиональном языке текстолога [8].

Реализация предложенного алгоритма в виде программы полного «жизненного» цикла текстологической классификации, начиная с этапа ввода и автоматической обработки текстов и заканчивая визуализацией результатов классификации, представляется весьма актуальной.

Входные данные по каждой рукописной традиции (совокупности сохранившихся списков исторического текста) представлены в программе в виде коллекции текстовых файлов.

Домой В начало Admin Выйти

### Предсловие Покаянию

1

Выбор файла: Не выбран ни один файл Загрузить

Способ чтения  
слева направо: ☉ | справа налево: ☾

Имя файла	
~\$ф_1262.doc	<a href="#">Скачать</a>
КС-81.txt	<a href="#">Скачать</a>
РМ-238.txt	<a href="#">Скачать</a>
Соф-1262.txt	<a href="#">Скачать</a>

[К сличению](#)

Рис. 1. Входные данные программы в виде коллекции текстов

Одним из проблемных этапов при использовании формальных инструментов текстологической классификации является предварительное сравнение (сличение) текстов, необходимое для формирования узлов разночтений. Для решения задачи автоматизированного сличения автор развивает вариант множественного выравнивания последовательностей с нечетким сравнением слов. Далее в программе предусмотрена возможность коррекции полученного разбиения на узлы разночтений со стороны пользователя.

Домой В начало Admin Выйти

### Предсловие Покаянию

1

0

Разночтение:  Номер узла:  Добавить

Порог четкости: 0.5 Сличить

Номер узла	Разночтение	Тип ошибки	Код неразичности ошибки
0	Подобает		
0	Подобает		
1	быти		
2	ерею		
2	попом		
2	попомъ		

N п/п	Список	Список	Код ошибки
1	7027	Соф-1262.txt	0
2	7028	КС-81.txt	0
3	7029	РМ-238.txt	0

Рис. 2. Форма для коррекции разбиения коллекции текстов на узлы разночтения

На основе попарного сличения текстов, полученных на предыдущем этапе, формируется матрица нечеткого отношения предпочтения, являющаяся, в свою очередь, исходной для последующего этапа классификации. Значениями рассматриваемой матрицы являются доли унаследованных ошибок (уклонений от нормальных чтений текста) из одного списка в другой, характеризующие тем самым направление («стрелу времени») и величину генеалогической близости (силу связи) соответствующей пары списков.

Поскольку число ошибок в каждом списке различно, то эта матрица не является симметричной (значения ее элементов, симметричных относительно главной диагонали, не совпадают). В отличие от симметричной матрицы близости кластерных методов [4], матрица нечеткого отношения содержит в себе возможность как группирования текстов списков (горизонтальный срез), так и их хронологического упорядочивания (вертикальный срез).

Этот содержательный вывод можно облечь с помощью аппарата теории нечетких множеств в формализованную процедуру, разбивающую исходное нечеткое отношение на две составляющие: симметричную (отношение эквивалентности) и антисимметричную (отношение порядка). Другими словами, удастся разбить исходное множество списков на текстологически близкие классы и установить между ними генеолого-преемственные связи.

Варьирование внешнего параметра нечеткой классификации – порога нечеткости (или противоположного ему порога надежности) – позволяет уточнить состав отдельных групп списков, выявить неявные взаимосвязи как между группами, так и отдельными списками. Для учета данного параметра в модели автор расширяет классические определения ряда свойств [9] нечетких отношений.

Авторский комплекс методов интеллектуального текстологического моделирования был апробирован для анализа древнерусских текстов («Закон Судный людем», X в.; «Предсловие покаянию», XII в.)

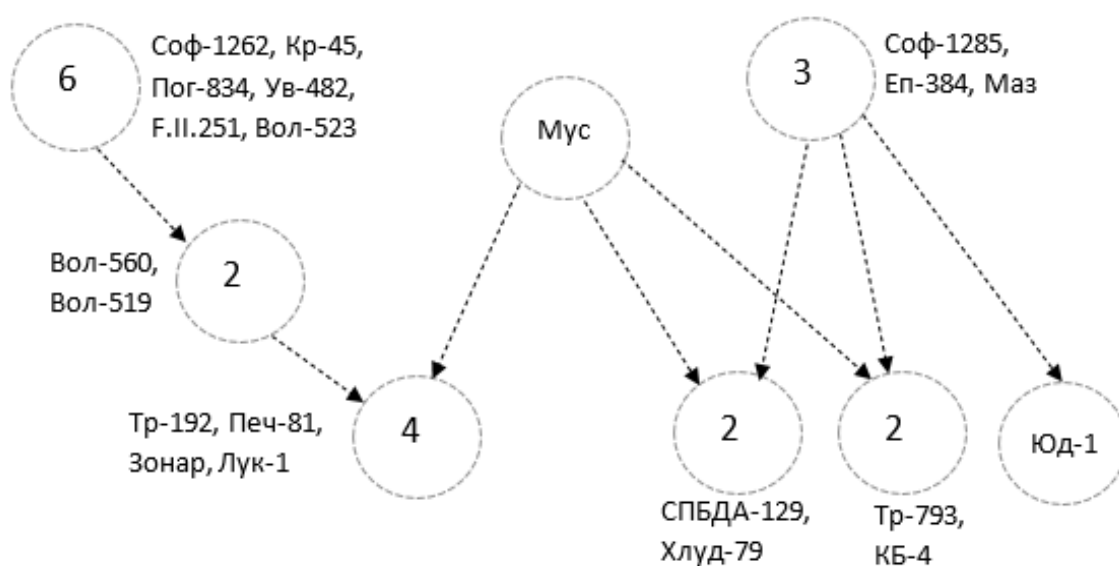


Рис. 3. Стемма «Предсловия покаянию» (порог надежности 0,57)

Цифрами на рис. 3 обозначено число списков в соответствующей группе.

Как мы видим из того же рисунка, предложенный подход допускает правку копиистами списков (наличие у списка или группы списков нескольких непосредственных предков).

Также важной особенностью предложенного подхода является решение проблемы уменьшения субъективной составляющей при оценке качества различий. В частности, известный метод косвенной экспертизы дополняется вычислением коэффициентов значимости элементов типологического ряда [10].

**Заключение.** Реализация инструментария интеллектуального текстологического моделирования на основе моделей нечеткого распознавания, позволяет существенно расширить сферы применения искусственного интеллекта в логико-лингвистических исследованиях как таковых, так и в других сферах гуманитарных наук.

Программный комплекс позволяет аккумулировать опыт различных методологических подходов, в результате которых формируются критерии текстологической классификации и кластеризации.

Перспективным представляется применение «Комплекса интеллектуального текстологического моделирования» в системе подготовки (и переподготовки) кадров по ряду направлений гуманитарных, исторических, социоправовых и управленческих наук.

«Комплекс интеллектуального текстологического моделирования» имеет не только прикладное, но и самостоятельное значение для исследователей, профессиональные интересы которых лежат в области интеллектуального анализа текстов (маркетинг, документоведение и архивоведение, информатика и пр.)

### Библиографический список

1. Бородкин Л.И., Милов Л.В. О некоторых аспектах автоматизации текстологического исследования (Закон Судный людям)// Математические методы в историко-экономических и историко-культурных исследованиях/ ред. И.Д. Ковальченко. – М., 1977. – С.235-280.
2. Бородкин Л.И. Математические модели классификации древних текстов// Методы количественного анализа текстов нарративных источников. Сборник статей. – М., 1983. – С.8-29.
3. Кузнецов С.О., Финн В.К. Об одной модели обучения и классификации, основанной на операции сходства// Обозрение прикладной и промышленной математики. – М., 1996. – Т.3 – Вып.1. – С. 67-89.
4. Прикладная и компьютерная лингвистика/ ред. И.С. Николаев, О.В. Митренина, Т.М. Ландо. – М., 2016. – 320 С.
5. Архангельский Т., Мишина Е., Пичхадзе А. Система электронной разметки древнерусских и церковнославянских текстов // *Palaeobulgaria* Старобългаристика. – София, 2014. – (XXXVIII) – № 4. – С. 21–37.
6. Баранов В.А. Проект «Манускрипт»: предварительные итоги. // Современные информационные технологии и письменное наследие: от древних текстов к электронным библиотекам. ЕІ' Manuscript-08: материалы Международной научной конференции (Казань, 26 – 30 августа 2008 г.) – Казань, 2008. – С. 32-36.
7. Корниенко С.И., Черепанов Ф.М., Ясницкий Л.Н. Распознавание текстов рукописных и старопечатных книг на основе нейросетевых технологий // Современные информационные технологии и письменное наследие: от древних текстов к электронным библиотекам. ЕІ' Manuscript-08: материалы Международной научной конференции (Казань, 26 – 30 августа 2008 г.) – Казань, 2008. – С. 155-156.
8. Шпирко С.В. Применение теории нечетких множеств к задаче генеалогической классификации в текстологическом исследовании// Историческая информатика: Информационные техноло-

гии и математические методы в исторических исследованиях и образовании. Барнаул, 2013. – № 3. – С. 39-51.

9. Мелихов А.Н., Бернштейн Л.С., Коровин С.Я. Ситуационные советующие системы с нечеткой логикой. – М., 1990. – 272 С.

10. Шпирко С.В., Баранкова Г.С. О некоторых аспектах построения формализованной генеалогической классификации текстов списков средневекового произведения с применением теории нечетких множеств (на материале «Закона Судного людем») // Исторический журнал: научные исследования. – 2017. – № 1. – С. 56-64.

## ON ONE APPROACH TO INTELLIGENT TEXT ANALYSIS

*Shpirko Sergey Valerievich*

Russian State University for The Humanities,  
Department of Intelligent Systems in the Humanities,  
119313, Russia, Moscow, Leninsky prospekt, 88-3-122  
shpirkos@mail.ru

The paper presents a description of the concept of an intelligent textual modeling software package, its structure and functions. The author's software package allows solving problems of textual classification with a given degree of fuzziness. The paper reveals the conceptual foundations of text analysis based on the methodology of fuzzy text recognition. The considered software package of intelligent textual modeling was tested for the analysis of some Old Russian texts.

**Keywords:** fuzzy recognition model, computer textology, stemma, multiple alignment algorithms, text collection, fuzzy genealogical classification.



## Секция: Искусственный интеллект, социология, политология, психология и криминалистика

УДК 004.032.26

### ТРУДОВОЕ ПОВЕДЕНИЕ В ЭПОХУ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

***Ильина Елизавета Николаевна***

Национальный исследовательский Нижегородский государственный  
университет им. Н. И. Лобачевского,  
603022, Россия, г. Нижний Новгород, пр. Гагарина, 23  
ilyinaelizabetha12@gmail.com

Искусственный интеллект (далее – ИИ) стремительно развивается, трансформируя различные аспекты жизни, в том числе и рынок труда. В статье представлено описание трудового поведения в контексте использования технологий искусственного интеллекта. Проведено комплексное социологическое исследование, позволяющее прояснить отношение к использованию ИИ в рабочих задачах.

**Ключевые слова:** профессии, квалификация, рынок труда, трудовое поведение, трансформации рынка труда.

**Введение.** Теория социального действия Э. Гидденса основана на понятии «структуризации». Структуризация – это процесс, посредством которого социальные структуры и индивидуальные действия взаимно формируют друг друга. Социальные структуры, такие как рынок труда, технологии и культурные нормы, ограничивают и направляют поведение людей в нужное русло. Однако люди также являются непосредственными активными агентами, которые могут интерпретировать и изменять социальные своими действиями и отношением к конкретному явлению. Применяя теорию Э. Гидденса к трудовому поведению в эпоху ИИ, можно проанализировать, как социальные структуры и индивидуальные действия влияют друг на друга в формировании отношения людей к использованию ИИ на рабочем месте.

Технологии ИИ представляют собой новую социальную структуру, которая влияет на рынок труда и требования, выдвигаемые к навыкам современного работника. Автоматизация задач может привести к потере рабочих мест, а новые технологии требуют новых навыков. Культурные нормы также влияют на отношение людей к ИИ. В некоторых культурах ИИ воспринимается как *угроза*, а в других – как *возможность*, поскольку именно люди являются активными агентами, которые интерпретируют социальные структуры и реагируют на них. Их отношение к использованию ИИ на рабочем месте будет зависеть от их восприятия и оценки влияния ИИ на их работу, требования к навыкам и дальнейшей возможности карьерного роста или отсутствия таковой.

Так, теория социального действия Э. Гидденса является полезным научным фундаментом для понимания трудового поведения в эпоху ИИ. Применяя эту теорию, мы можем проанализировать, как социальные структуры и индивидуальное действие взаимодействуют в формировании отношения людей к использованию ИИ на рабочем месте. Изучение форм данных взаимодействий играет главную роль для разработки дополнительных образовательных и/или государственных программ, направленных на подготовку работников к будущему рынка труда, основанному на внедрении ИИ.

Основываясь именно на данной теории, был составлен онлайн-опросник для проведения количественного социологического исследования (n=307 респондентов, представителей различных профессий Нижегородской области). Опросник включал в себя вопросы об отношении респондентов к использованию ИИ в рабочих задачах, их восприятию влияния ИИ на их работу и требования к навыкам. Количественное исследование было дополнено качественным – контент-анализом материалов интервью – также об ожиданиях респондентов относительно грядущих трансформаций рынка труда, что гарантировало комплексность настоящего социологического исследования (n=58 респондентов, представителей различных профессий Нижегородской области).

**Опыт «взаимодействия» с ИИ.** Чуть больше половины опрошенных (52%) так или иначе имели опыт использования средств ИИ в решение своих текущих рабочих задач. Направления же работы с ИИ в данном случае были условно разделены автором на четыре основных направления. Так, путём сравнительного анализа материалов онлайн-опроса и интервью, были получены ключевые механизмы «помощи» искусственного интеллекта в работе простого современного обывателя, не имеющего специализированной подготовки (рис. 1).




Рис. 1. Направления использования ИИ, %

На основе представленной гистограммы можно выделить следующие основные направления использования искусственного интеллекта для решения рабочих задач:

**Автоматизация рутинных задач** – около 52%. Это направление занимает лидирующую позицию в использовании ИИ. Автоматизация рутинных задач позволяет значительно повысить эффективность работы, снизив затраты времени и сил на повторяющиеся процессы. Примеры данного использования

средств ИИ могут включать автоматическую обработку данных, управление документами, выполнение стандартных операций и другие задачи, которые обычно требуют значительных временных ресурсов, но имеют предсказуемый алгоритм выполнения.

**Написание текстов** – 27%. Второе по популярности направление использования ИИ. Генерация текстов с помощью ИИ находит применение в таких областях, как написание статей, создание маркетинговых материалов, разработка контента для веб-сайтов и социальных сетей, а также автоматизация отчетов. Это позволяет создавать тексты на основе данных, минимизируя участие человека в процессе написания.

**Генерирование изображений.** Приблизительно 20% от общего числа пользователей ИИ используют его для создания изображений. Это может быть полезно для дизайнеров, рекламных агентств, а также в креативных индустриях. ИИ может генерировать изображения по заданным параметрам или создавать уникальные визуальные материалы для использования в различных проектах.

**Анализ данных** – около 10%. Наименее популярное направление, но тем не менее важное. Анализ данных с помощью ИИ помогает обрабатывать большие объемы информации максимально быстро, выявлять закономерности, проводить прогнозирование и оптимизацию бизнес-процессов. Это особенно актуально для компаний, работающих с большими данными, а также в таких областях, как финансы, маркетинг и исследовательская деятельность.

Так, основное внимание в использовании ИИ сосредоточено на автоматизации рутинных процессов, что говорит о стремлении предприятий к оптимизации трудозатрат. В то же время использование ИИ для генерации текстов и изображений также активно развивается, особенно в креативных и контент-ориентированных областях (наибольшая корреляция данного направления использования ИИ была продемонстрирована среди пользователей-представителей маркетинговых направлений IT-сфер). Анализ данных пока не так широко применяется, что может свидетельствовать о необходимости дальнейшего развития инструментов для обработки информации и повышения доверия к ним среди пользователей. Справедливо предположить, что в настоящий момент автоматический анализ данных, лишенный «человеческого» взгляда, демонстрирует меньшую эффективность по сравнению с более простыми функциями ИИ.

**Преимущества и недостатки использования ИИ в работе.** Данные настоящего исследования позволяют сделать ряд выводов о восприятии обывателями преимуществ искусственного интеллекта (рис. 2). Наиболее выраженным преимуществом ИИ, согласно полученным данным, является автоматизация рутинных задач, набравшая 72,9%. Это говорит о том, что широкая общественность в первую очередь видит в ИИ технологию, способную освободить человека от монотонных и повторяющихся действий, тем самым повышая эффективность и продуктивность труда.




Рис. 2. Преимущества ИИ, %

Вторыми по значимости, с одинаковым показателем в 35,4%, идут новые возможности для креатива и инноваций, а также увеличение производительности труда. Это демонстрирует, что ИИ рассматривается не только как инструмент для оптимизации существующих процессов, но и как двигатель прогресса, способный открыть новые горизонты в области творчества и исследований.

Следующим преимуществом является повышение точности и качества работы (29,2%). Это преимущество отражает потенциал ИИ в улучшении результатов деятельности в различных сферах, где точность и качество имеют ключевое значение.

Представленная на рис. 3 диаграмма демонстрирует основные опасения общества, связанные с развитием искусственного интеллекта. Наиболее ярко выраженной проблемой, согласно этим данным, являются проблемы с защитой персональных данных (56,3%). Это отражает повсеместное беспокойство о конфиденциальности и безопасности личной информации в эпоху цифровизации. Люди опасаются, что ИИ может быть использован для незаконного сбора, хранения и использования их персональных данных. Например, ИИ может быть использован для создания *deepfake*-материалов – фальшивых видео или аудио с использованием персональных данных (например, изображений или голоса человека) – что может привести к мошенничеству или клевете. Также, ИИ может хранить персональные данные в обход законов о защите данных (например, GDPR в Европе). Эти данные могут использоваться для аналитики, разработки моделей поведения или передаваться третьим лицам без ведома и согласия пользователя.



Рис. 3. Недостатки ИИ, %

Вторым по значимости является вопрос проблем с этикой и безопасностью ИИ (52,1%). Сюда входят опасения о непредсказуемости и потенциальной опасности искусственного интеллекта, который может принять неконтролируемые решения или стать угрозой для человечества. Третьим по значимости является сложность адаптации к новым технологиям (29,2%). Это отражает беспокойство о том, что быстро развивающийся мир ИИ может быть слишком сложным для понимания и применения большинством людей. Следующим по значимости является угроза потери рабочих мест (27,1%). Респонденты выражают опасения о том, что ИИ может заменить людей на многих рабочих местах, что может привести к массовой безработице. Замыкает список риск возникновения трудового неравенства (16,7%). Их всех потенциальных угроз респонденты меньше всего верят, что ИИ может усилить разрыв между богатыми и бедными, поскольку доступ к ИИ и его преимуществам может быть неравномерным. Однако, технологии ИИ становятся более доступными не только для крупных корпораций, но и для малых и средних предприятий. Облачные решения и сервисы на основе ИИ позволяют даже небольшим компаниям получать доступ к сложным аналитическим инструментам, которые могут улучшить их конкурентоспособность. Более того, благодаря ИИ появляются новые образовательные платформы, которые могут предоставлять качественные и персонализированные учебные материалы широкому кругу людей, включая тех, кто ранее не имел доступа к хорошему образованию.

**Работа с ИИ в перспективе.** На основании материалов интервью были сформулированы основные тренды в представлении работы с ИИ в обозримом будущем:

**Автоматизация рутинных процессов.** Уменьшение рабочих мест, особенно в профессиях, связанных с стандартизированными или повторяющимися задачами. Это касается таких сфер, как HR, юриспруденция, маркетинг, и многие другие. Ускорение выполнения рутинных задач, повышение производительности. Например, сокращение сроков подбора кандидатов и обработки данных.

**«Некреативный» креатив.** Некоторые респонденты отмечают, что ИИ сложнее внедрить в креативные профессии, такие как контент-маркетинг и ди-

зайн. Однако, если это произойдет, роль неквалифицированных сотрудников может сократиться.

**Рост эффективности и качества работы.** ИИ может повысить качество аналитических данных и их доступность. Это также касается улучшения социальных прогнозов и использования новых методов интерпретации данных. В таких областях, как PR, коммуникации, и маркетинг, ИИ может помочь более эффективно взаимодействовать с аудиторией путем генерации контента, к активному потреблению которого так привык современный обыватель.

**Позитивное восприятие ИИ.** Многие участники интервью выражают оптимизм по поводу внедрения ИИ, предполагая, что он облегчит им жизнь, уменьшит административные расходы и освободит время для более сложных задач. Позитивное влияние ожидается в областях маркетинга, разработки контента, создания концепций и визуальных возможностей.

Однако, имеют место также **скептические настроения**. Некоторые участники интервью высказывают сомнения относительно значимого влияния ИИ в своих областях, особенно в креативных профессиях. А другие «предсказывают», что, несмотря на автоматизацию, ИИ не сможет полностью заменить людей в профессиях, требующих эмоционального интеллекта и человеческой вовлеченности (например, психолог). Также многие респонденты отмечают, что влияние ИИ будет зависеть от времени и развития технологий, подчеркивая, что пока трудно однозначно предсказать, какие именно изменения произойдут.

В краткосрочной перспективе внедрение ИИ, скорее всего, окажет большее влияние на административные и аналитические профессии, высвобождая время для более сложных задач. В долгосрочной перспективе могут пострадать рабочие места, связанные с рутинной, но креативные профессии будут дольше сопротивляться полной автоматизации. Прогнозируется увеличение производительности и качества работы в компаниях, активно внедряющих искусственный интеллект. Он будет не только инструментом для повышения эффективности, но и возможной причиной изменения структуры рабочих мест. Однако, несмотря на угрозу автоматизации, творческие и эмоциональные аспекты многих профессий останутся в зоне человеческой ответственности.

### Библиографический список

1. Абашкин В.Л., Абдрахманова Г.И., Вишневский К.О. и др. Цифровая экономика 2024: краткий статистический сборник // Нац. исслед. ун-т «Высшая школа экономики». Москва: ИСИЭЗ ВШЭ, 2024. 124 с.
2. Валецкая Т.И., Плещенко Е.А. Влияние искусственного интеллекта на рынок труда // Ученые записки Алтайского филиала Российской академии народного хозяйства при Президенте Российской Федерации. 2024. №1 (24). С. 36-39.
3. Ефремова Е. Ю. Роботизация труда: перспективы и угрозы // Вестник НИБ. 2019. № 37. С. 83-88.
4. Нарейко В.Г. Искусственный интеллект в управлении персоналом // НПЖ «Диалог». 2022. №1 (21). С. 50-53.

# WORK BEHAVIOR IN THE AGE OF ARTIFICIAL INTELLIGENCE

*Ilyina Elizaveta Nikolaevna*

National Research Lobachevsky State University of Nizhny Novgorod,  
603022, Russia, Nizhny Novgorod, Prospect Gagarina, 23  
ilyinaelizaveta12@gmail.com

Artificial intelligence (hereinafter referred to as AI) is rapidly developing, transforming various aspects of life, including the labor market. The article presents a description of labor behavior in the context of using artificial intelligence technologies. A comprehensive sociological study was conducted to clarify the attitude towards the use of AI in work tasks.

**Keywords:** professions, qualifications, labor market, labor behavior, labor market transformations.

УДК 004.032.26

## АЛГОРИТМ И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ РАСПОЗНАВАНИЯ МОНОЗИГОТНЫХ БЛИЗНЕЦОВ И ОТЦОВСТВА

*Липин Юрий Николаевич*

Пермский национальный исследовательский политехнический университет  
614068. Россия. Пермский край. г. Пермь, ул. Комсомольский проспект, д.29  
kapc@pstu.ru

В статье дано описание алгоритма с программным обеспечением определения адекватности монозиготных близнецов (однояйцевых) при условии их абсолютной схожести от рождения по цвету лица, глаз, архитектуры черепа головы, черт лица, и ДНК. При обычном распознавании находится степень близости параметров двух фото через их вектора, а в данной задаче необходимо найти их отличие друг от друга, т.е. определить кто есть/’ Мария’ и кто есть ‘Наталия’. Представляет интерес с точки зрения алгоритмизации выявить возможность использовать алгоритмы распознавания в проблеме отцовства.

**Ключевые слова.** Близнецы, монозиготные, асимметрия лица, фото, вектор лица.

**Введение.** Поставленная проблема является весьма важной и трудно решаемой задачей. При обычном распознавании, как в пропускных системах, определяется сходимость двух образцов. В данном случае сходимость с учетом палитры цветов по каналам цветности и архитектуры лиц близнецов даст почти сто процентную сходимость. В основе алгоритма используется данная нам от природы исходная асимметричность половин лица и прочих частей тела. Также от рождения создается некоторая асимметричность глаз, губ, бровей, рта, овала лица. Алгоритм усиливает эту асимметрию за счет создания еще двух образов из фото левых и правых половин лица, плюс два дополнительных, как средних фото. Итого в анализе используется восемь фото.

**Постановка задачи.** Из введенного фото создаются еще два фото из левых и правых половин лица и четвертое фото, как сумма двух созданных. Итого

для анализа будут использованы восемь фото посредством обработки восемь матриц по каждому фото. Каждая матрица преобразуется специальными фильтрами, позволяющими определить контур лица и поддерживать яркость и контрастность в определенных значениях

### **Проблемы распознавания монозиготных лиц.**

Распознавание монозиготных близнецов по изображениям их лиц является сложной задачей в биометрии, и оно зависит от видов близнецов. Однояйцевые близнецы [1] (монозиготные) образуются, когда одно оплодотворенное яйцо делится на две отдельные эмбриональные клетки. Характерными свойствами их являются. **Универсальность, Уникальность, Приемлемость** – это факторы, которые следует учитывать и который показывает, в какой степени люди готовы принять биометрическую систему. У данного типа близнецов общими параметрами являются пол, цвет волос, глаз, палитра цветов, черты лица, объекты лица, контур лица, ДНК отпечатки пальцев.

**Анализ традиционных методов распознавания.** Автор имеет многолетний опыт [6, 10] в распознавании различных объектов с соответствующими публикациями. (Распознавании лиц, голоса, асимметрии лица и полушарий мозга, подписи, анализ подписи, отпечатков пальцев). Необходимо отметить, что основным источником информации о лице является его цветовая палитра через цвет пикселей. Основное изображение пропускается через фильтр Собеля с получением черно-белого контрастного вида, позволяющее находить границы изображения лица. Следующим этапом стал период использования правил золотого сечения [11, 16]. Отношение малого к большому равно 1.618 какой-то целой части. По черно-белому изображению лица программа находит положение бровей, по ним шесть вертикальных и горизонтальных отрезков и получает программа 25 прямоугольников, по каждому используется преобразование Фурье с получением вектора из 25 значений. Необходимо отметить, что формирование образа лица в векторах происходит от частного к общему представлению. Мозг человека распознает объекты по другой схеме – сначала картина в целом, затем детали в среднем за 70 мсек. Автором был разработан алгоритм и программа под идею работы мозга [16]. Использовались два фильтра – Собеля и High Pass, второй для повышения контрастности и яркости.

Факт асимметрии лица является общепризнанным и выражается неравнозначностью правой и левой частей. Причиной данной асимметрии, в большинстве случаев, является неравномерность элементов костного черепа, а на лице степень ее проявления можно объяснить специфичностью мимики.

На входе имеем фото этого типа близнецов рис.1.

Обычные программы распознавания дают стопроцентную сходимость. Доказательством наличия асимметрии нормального человеческого лица служит метод создания изображения одного и того же лица из двух левых и двух правых половин [10, 16]. Таким образом, создаются два дополнительных фото с абсолютной симметрией, но значительно отличающихся от оригинала. В данной разработке на основании входного лица создаются еще три фото, т.е. два фото близнеца используется восемь фото, что значительно усиливает эффект асимметрии лица /Загрузим программу и получим входную форму. Рис.2





Рис. 1. Фото двух однайцевых близнецов




Рис. 2. Результат работы программы

На рис. 2. дана выходная форма программы. Верхний ряд слева направо: левые половины первого фото близнеца, первое фото первого близнеца, левое фото второго близнеца, второе фото второго близнеца. Нижний ряд слева направо: правые половины лица первого близнеца, сумма среднего правых и левых половин первого близнеца, правые половины второго близнеца, среднее фото левых, правых половин второго близнеца. Создается база данных из восьми фото. На вход подается первый близнец и в процентах выводится ответ, затем на вход подается второе фото и тоже выводится ответ. Точность ответов равняется длине мантиссе вещественных форматов, т.е.  $10^{(-11 \text{ зн})}$ .

**Итоги Работы программы.** Вводим фото первого Близнеца и получаем еще три фото. Из левых половин лица, из правых половин лицо и среднее из них. Вводим второе фото близнеца и получаем еще таких же три фото, т.е. для анализа лається восемь фото. Эти восемь фото формируют базу данных в виде  $Mst2[I, J]$ , входной поток будет в виде фото первого близнеца  $Mst1[1, J]$ . Каждое фото по правилам золотого сечения формирует сетку прямоугольников из 25 штук. По каждому из них выполняется преобразование Фурье с привязкой каждой амплитуды гармоники к конкретному пикселю. В конечном каждое фото представлено в виде вектора из 25 значений.

При запуске программы получаем результат;

### 1. Входной поток-фото первого близнеца

100% – Первое фото Близнеца;

100%- Фото из левых половин его;

100%- Фото из правых половин его;

100%- Среднее фото их левых и правых половин его;

93,313917883% – Второе фото близнеца;

93,313917883%- Левые половины из второго фото;

93,313917883%- Правые половины из второго фото;

93,313917883%- Среднее из правых и левых половин;

Первое фото само на себя дало 100% подобия, первое фото со вторым фото близнеца дало 93% адекватности, после запятой 9 знаков.

### 2. Входной поток- фото второго близнеца

100%- первый близнец

99,86698207928%- тоже, что и выше

98,11609849364%ва 23 год.

99,04828749328%

99,72258807547%- Второй близнец

99,67798931826%- тоже, что и выше

98,34522320243%

99,073201138%

Анализ данных дает разный результат – первый близнец 93,3% и второй близнец- 99,7%, что можно принять предложенный алгоритм с программой для практической работы.

### Определение отцовства по фото Отец-Сын.



Рис. 3. Сын слева 89 лет, отец справа 23 года

Результат распознавания 95% по отцу и сыну. С использованием алгоритма распознавания Мозга без применения даже фильтра Фурье.

Начало потока= 17:39 :13 :0

**AVG= 162 Дано сын найдено 92,63276841609%**

Конец идентификации лица ч.м.с. = 17:39 :13 :253

распознавание % N = 99..100% 0

распознавание % N = 96..98% 0

**распознавание % N = 93..95% 1**

Время Распознавания на одно фото Мсек.в потоке = 6

Конец создания базы = 17:39:13

## Определение отцовства по детским фото.



Рис. 4. Будущий отец 2.5 года, 2 – 2.5 Дочь, 3 – 18 лет – предполагаемая дочь, 4 – предполагаемый сын

Фактически по жизни **1, 2, 3** подтверждено, **4** – нет.

Начало потока= 18:23 :5 :0

AVG= 149 Дано образец2 найдено 90,42184855767%

AVG= 149 Дано образец3 найдено 91,66066186034%

AVG= 149 Дано обрац4 найдено 48,94481591961%

AVG= 149 Дано сам найдено 1 99,9595959596%

Конец идентификации лица ч.м.с. = 18:23 :5 :723

распознавание % N = 99..100% 1

распознавание % N = 96..98% 0

распознавание % N = 90..92% 2

распознавание % N = 1..67% 1

Время Распознавания на одно фото Мсек.в потоке = 2

Конец создания базы = 18:23:05

Выводы

### Выводы

1. Предложен алгоритм, основанный на внутренней незаметной для глаза асимметрии лица человека через его модель по вектору с обработкой фото;

2. На основании входного фото создаются алгоритмом через программу еще три фото, пропускаются через преобразование Фурье с формированием вектора с 28 значениями для обоих близнецов;

3. Применение алгоритмов распознавания в проблеме отцовства Отец-Сын выполнено с достаточной степенью доверия. Представляет интерес решения этой задачи в случае анализа детских фото будущего отца и малолетних детей. Алгоритм позволил получить достоверные результаты даже в случае разного пола и возрастов. Будущему отцу по фото было 2.5 года и разные возраста в 2.5 г. и 18 лет и эта разница на результаты не повлияла.

### Библиографический список

1. Г. М. Савельева, В. И. Кулаков. Акушерство. – М.: Медицина, 2000. – С. 816. – ISBN 5-225-04549-9

2. Основы психогенетики. Дата обращения: 23 ноября 2018. Архивировано 8 ноября 2016 года.
3. Марина Егорова, Светлана Пьянкова. Динамика близнецовой рождаемости в России (1959–2008) // Психологические исследования. – 2010-10-31. – Т. 3, вып. 13. – ISSN 2075-7999. – doi:10.54359/ps.v3i13.893. Архивировано 2 апреля 2022 года
4. АК Джайн, А. А. Росс, К. Нандакумар, Введение в биометрию (Springer Science Business Media, Нью-Йорк, 2011), стр. 978-0387773254.
5. Анбарджафари, Распознавание лиц с использованием цветового локального бинарного шаблона из взаимно независимых цветовых каналов. EURASIP J. Процесс обработки изображений и видео. 2013 (1), 6 (2013).
6. Липин Ю.Н., Сторорожев С.А. Разработка программы моделирования алгоритмов систем распознавания лиц // VIII Всерос. науч.-практ. конф. с междунар. участием "Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века".
7. Lipin YU.N. Stororozhev S.A. Development of an algorithm for human face recognition (2021 International Conference on Data Analytics for Business and Industry (ICDABI)). (In Russ.).
8. Lipin YU.N., Stororozhev S.A. Razrabotka programmy modelirovaniya algoritmov sistem raspoznaniya lic (VIII Vseros. Nauch.-pract. konferenciya s mezhdunarodnym uchastiem "Iskusstvennyj Intellect v reshenii ak-tual'nyh social'nyh i ekonomicheskikh problem HKHI veka"). (In Russ ).
9. Yu. N. Lipin – Canidate in Technical Sciences, Associate Professor of the Department of Automatics and Telemechanics, Perm National Research Polytechnic University (29, Komsomolsky Prospekt, Perm, Russia, 614068).
10. Липин Ю.Н., Сторорожев. С.А. :Разработка программы моделирования алгоритмов систм распознавания лиц (VIII всероссийская научно практическая конференция с международным участием «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI
11. Тахов А.П. Коды золотой пропорции, Москва, Радио и связь, 1984 / 152 с.
12. Боднар О.Я. Золотое сечение и неевклидова геометрия в природе и искусстве. Львов, Изд-во «Свит», 1994 / 204 с.с.
13. Ю. Н. Липин. Разработка алгоритма распознавания лиц с учетом особенностей работы человеческого мозга . Вестник Пермского университета. Математика. Механика. Информатика. 2022г.

## ALGORITHM AND SOFTWARE FOR THE ADEQUACY OF MONOZYGOTIC TWINS

*Yuri Lipin*

Perm Polytechnic University 614068. Russia. Perm Territory. Perm. Komsomolsky Prospekt. D.29  
caps@pstu.ru

The article describes an algorithm with software for determining the adequacy of monozygotic twins (identical) under the condition of their absolute similarity from birth in complexion, eyes, skull architecture, head features, facial features, and DNA. With ordinary recognition, the degree of proximity of the parameters of two photos through their vectors is found, and in this task it is necessary to find their difference from each other, i.e. to determine who is 'Maria' and who is 'Natalia'. This development will allow, in our opinion, to use it as an additional marker in the problem of DNA work. From the point of view of algorithmization, it is interesting to identify the possibility of using recognition algorithms in the problem of paternity. The researchers concluded that the shape of the face, ears and hairline are inherited from fathers to sons.

**Keywords.** Gemini, monozygotic, facial asymmetry, photo, face vector.

## ТЕНДЕНЦИИ ИЗМЕНЕНИЯ ИНФОРМИРОВАННОСТИ ИЗБИРАТЕЛЕЙ В СВЯЗИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

*Осмоловская Александра Андреевна*

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
osmolovskaya.a@gmail.com

В статье рассматривается влияние искусственного интеллекта на информированность избирателей и, как следствие, на эпистемическое многообразие, необходимое для принятия решений демократическим путем. Информированность избирателей зависит как от самой информации, так и от способа ее передачи. В этой связи показано влияние технологий искусственного интеллекта на автономию избирателей и их способность к суждению, что определяет эффективность принятия решений. В статье выдвигается тезис о том, что способ информирования с использованием искусственного интеллекта может приводить к снижению эффективности решений, принимаемых демократическим путем. Аргументация связана с особенностями технологий искусственного интеллекта, использование которых может негативно отразиться на принципах демократии, поскольку недостоверная или искаженная информация может оказываться основной для принятия решений.

**Ключевые слова:** искусственный интеллект, информированность избирателей, эпистемическое многообразие, автономия избирателей, эффективность принятия решений.

Условием эффективности решений, принимаемых демократическим путем, выступает эпистемическое многообразие избирателей. Для поддержания эпистемического многообразия необходимо сохранение автономии при принятии решений. Условием сохранения автономии, в свою очередь, выступает способность суждения, которая выражается в готовности определять и пересматривать собственные предпочтения, осуществлять выбор между набором альтернатив, выдвигать аргументы за и против и указывать на то, какие из них преобладают, а также проверять информацию на предмет ее достоверности. При этом способность суждения должна быть не просто присуща избирателю, но и регулярно применяться на практике. Только в этом случае способность суждения может условием сохранения автономии при принятии решений.

На эпистемическое многообразие влияет информированность избирателей, которая проявляется на разных уровнях. Прежде всего, информированность избирателей определяется тем, какая информация передается, а именно степень ее искаженности и предвзятости. Кроме того, информированность определяется способом передачи информации, который основан на той или иной технологии. Поэтому изменения в способе информирования отражаются не столько на характере передаваемой и получаемой информации, сколько на способностях самих избирателей [1]. В настоящей работе будут показаны изменения информированности избирателей, дискуссия о которой была развернута в конце XX века в связи с оценкой влияния радио и телевидения [2, 3], в связи с

использованием искусственного интеллекта. Цель работы состоит в том, чтобы показать, как особенности информированности влияют на эпистемическое многообразие избирателей, в том числе через автономию и способность суждения. Представляется, что в силу многообразия информации, роста ее доступности и недостаточного количества ресурсов для ее обработки автономия избирателя имеет тенденцию к снижению под влиянием искусственного интеллекта.

Проблема информированности избирателей впервые была поставлена в рамках делиберативного подхода в значении того эпистемического многообразия, которое представлено среди избирателей и которое во многом определяет ценность делиберации. В этом контексте на рост информированности избирателей могут повлиять внесение большего разнообразия в состав делиберативной группы, введение разделения эпистемологической работы или поощрение делиберации и дискуссии [4]. В конце XX века была развернута дискуссия об информированности избирателей. Одна из позиций в дискуссии предполагала, что, взаимодействуя с различными источниками информации, избиратель может отдавать предпочтение развлекательному контенту, что не будет способствовать росту информированности в политических вопросах [2]. Другая позиция, которая была представлена критической теорией, предполагала, что в существующих обстоятельствах информирование о политических вопросах сводится к пропаганде [3]. Первая позиция была представлена американским теоретиком медиа и критиком культуры Нилом Постманом, вторая позиция – точка зрения критической теории – была представлена Эдвардом Херманом и Ноамом Хомским.

В рамках дискуссии об информированности были поставлены две проблемы. Во-первых, это проблема характера передаваемой информации и того искажения, которому она подвергается, приобретая характер пропаганды. Во-вторых, это проблема влияния характера информации и способа информирования на избирателя, в частности, его мышление. Учитывая многообразие информации, роста ее доступности и недостаточное количество ресурсов для ее обработки, представляется, что именно изменение способностей самих избирателей оказывает большее воздействие на эффективность решений, принимаемых демократическим путем. Дальнейшее развитие технологий – таких как телекоммуникации, мобильные устройства, социальные медиа и искусственный интеллект – в еще большей степени оказало влияние на такие способности.

Далее необходимо обратиться к актуальному статусу дискуссии об информированности, связанному с использованием искусственного интеллекта и его влиянием на автономию избирателя. Вместе с развитием технологий и распространением новых способов информирования дискуссия вызывает вопрос об их влиянии на рост информированности избирателей и, как следствие, поддержание эпистемического многообразия. При этом особое внимание необходимо уделить не столько характеру передаваемой информации, сколько влиянию способов передачи на автономию избирателя.

Можно предположить, что использование искусственного интеллекта должно привести к появлению более информированных граждан, чем при использовании любого другого способа, учитывая возможность обработки боль-

ших объемов информации. Такой позиции придерживается Элен Ландемор, считая, что искусственный интеллект представляет собой эффективный инструмент для усиления эпистемического значения демократии [5]. Это оказывается возможным благодаря потенциалу для координации общественных обсуждений, в том числе через возможность более эффективной обработки информации, в частности ее обобщению. На этой основе кажется возможным создание и применение коллективного разума, который основан на информации, присущей большинству и необходимой для решения общественно значимых проблем. В этой связи можно предположить, что создаваемый сегодня общий искусственный интеллект (Artificial General Intelligence) [6, 7] может стать воплощением «коллективного разума» большинства («collective cognition») [8] или «мудрости множества» («wisdom of the multitude») [9].

Но при этом необходимо выделить ряд особенностей технологий искусственного интеллекта, использование которых может негативно отразиться на принципах демократии, поскольку недостоверная или искаженная информация может оказываться основной для принятия решений [10]. Во-первых, технологии искусственного интеллекта основаны на уже имеющихся данных, что противоречит принятию решений демократическим путем, которое часто основано на скрытых предпочтениях, эмоциях или интуиции. Избиратели часто фальсифицируют свои предпочтения, что становится частью данных для применения технологиями искусственного интеллекта. Поэтому то, что избиратели в действительности полагают истинным или полезным, может не быть частью данных. Участие избирателей в процессе принятия решений способствует регулярному приращению данных и обновлению алгоритмов на их основе, но в момент принятия решения такие данные обязательно отсутствуют в любой модели искусственного интеллекта, поскольку еще не существуют как общедоступная информация, поддающаяся классификации и агрегированию.

Во-вторых, технологии искусственного интеллекта включают использование алгоритмов. Действие алгоритмов предполагает возможность систематической замены информации, необходимой для принятия решения, искаженной или отвлекающей. В-третьих, использование технологий искусственного интеллекта снижает разнообразие индивидуального опыта, в том числе приобретаемого через интенсивность взаимодействия индивидов друг с другом. Индивидуальный опыт предполагает обращение к таким элементам, как эмоции и интуиция, которые не могут быть строго отражены через данные, но вместе с тем способны оказать влияние на принятие решений.

Таким образом, большинство избирателей под направленным воздействием технологий может лишиться того многообразия, которое и составляет глобально эпистемическое значение демократии. Одной из ключевых проблем влияния технологий искусственного интеллекта на демократию оказывается циклы обратной связи, поскольку эпистемически устаревшие агенты, обученные на уже имеющихся данных, будут оказывать влияние на принятие решений, что будет ограничивать появление новых предпочтений. При этом скрытые предпочтения, эмоции и интуиция нивелируются искусственным интеллектом, который закрепляет только уже существующие предпочтения.



Следствием этого может выступать отсутствие самой потребности в вынесении самостоятельных суждений, а также получении суждений от других избирателей в отношении общественно значимых проблем. Это приводит к исключению несогласия из политического дискурса, а как следствие исключению дискуссии, которая может способствовать более эффективному решению таких проблем. При этом по большинству таких проблем отсутствуют серьезные институциональные ограничения для выражения несогласия, но индивиды, даже имея доступ к информации, оказываются не готовы ей воспользоваться для того, чтобы принять самостоятельное решение. В этих условиях избиратель убеждается, что сложные проблемы можно преодолеть только предложенными решениями. Большинство не способно реализовать свой эпистемический потенциал под систематическим набором внешних воздействий, которые заставляют совершать ошибки в одном и том же направлении в одно и то же время.

Если бы значение имело только содержание передаваемой информации, то можно было бы говорить о росте эпистемического многообразия как следствии применения технологий искусственного интеллекта благодаря широким возможностям ее обработки. Но, поскольку для демократии более важное значение имеет способ информирования, в частности, передача готовых суждений, применение таких технологий может приводить к снижению эпистемического многообразия в связи с потерей автономии избирателей, которая определяется не только наличием способности суждения, но и ее регулярной практикой, в том числе в отношении общественно значимых вопросов. Таким образом, современные тенденции информирования избирателей приводят к снижению эпистемического многообразия, тем самым снижая эффективность принятия решений демократическим путем.

### **Библиографический список**

1. Carter, J.A. (2017). Intellectual autonomy, epistemic dependence and cognitive enhancement. *Synthese*, 197, 2937-2961.
2. Postman, N. (1985). *Amusing ourselves to death: public discourse in the age of show business*.
3. Herman, E.S., & Chomsky, N. (1988). *Manufacturing Consent. Power and Inequality*.
4. Goodin, R.E., & Spiekermann, K.P. (2018). *An Epistemic Theory of Democracy*. Oxford Scholarship Online.
5. Landemore, H. (2022). Can AI Bring Deliberative Democracy to the Masses? In *HAI Weekley Seminar* (2022): 1-35.
6. Jungherr, A. (2023). *Artificial Intelligence and Democracy: A Conceptual Framework*. *Social Media + Society*, 9.
7. Xu, B. (2024). What is Meant by AGI? On the Definition of Artificial General Intelligence. *ArXiv*, abs/2404.10731.
8. Farrell, H., Washington, G.T., & Shalizi, C.R. (2012). *Cognitive Democracy*.
9. Waldron, J. (1995). The Wisdom of the Multitude. *Political Theory*, 23, 563-584.
10. Risse, M. (2023). *Political Theory of the Digital Age*.



## TRENDS IN VOTER AWARENESS RELATED TO THE USE OF ARTIFICIAL INTELLIGENCE

*Aleksandra A. Osmolovskaia*

Perm State National Research University,  
Str. Bukireva, 15, Perm, Russia, 614068  
osmolovskaya.a@gmail.com

The article examines the impact of artificial intelligence on voter awareness and, as a result, on the epistemic diversity necessary for democratic decision-making. Voter awareness depends on both the information itself and the way it is transmitted. In this regard, the influence of artificial intelligence technologies on the autonomy of voters and their ability to judge, which determines the effectiveness of decision-making, is shown. The article puts forward the thesis that the method of informing using artificial intelligence can lead to a decrease in the effectiveness of decisions made democratically. The argument is related to the peculiarities of artificial intelligence technologies, the use of which can negatively affect the principles of democracy, since unreliable or distorted information can be the main one for decision-making.

**Keywords:** artificial intelligence, voter awareness, epistemic diversity, voter autonomy, decision-making efficiency.

УДК 004.032.26

## НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ СКЛОННОСТИ К СЕРИЙНЫМ УБИЙСТВАМ

*Пономарев Александр Федорович*

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
airsunday2001@gmail.com

В статье представлено описание разработки нейросетевой системы для определения склонности человека к серийным убийствам по типовым признакам. Данные для исследования основаны на биографии существующих серийных убийц, а также обычных людей, которые могли бы оказаться в схожих условиях. Исследование не несет в себе практический характер, из-за неэтичности разрабатываемой системы.

**Ключевые слова:** искусственный интеллект, нейросетевые технологии, прогнозирование, маньяк, серийные убийства.

**Введение.** Можно ли судить человека по генетическому коду, заложенному ему с рождения? Обратимся к исследованиям Каролинского института гена MAOA или «Ген воина» [1]. Результаты исследования, пусть и оказались противоречивы, но свидетельствуют, что ген может способствовать примерно 5-10 % тяжким насильственным преступлениям в Финляндии. Подобными исследованиями так же занимается нейрокриминалогия, применяя методы визуализации мозга и принципы из нейробиологии для понимания, прогнозирования и предотвращения преступлений. Значимой фигурой в нейрокриминалогии можно считать итальянского психиатра и тюремного врача Чезаре Ломброзо [2].

В своих исследованиях он был убежден, что преступление возникает из-за аномалий мозга. Также в своих исследованиях пришел к выводу, что гениальность тесно связана с безумием, и ее можно назвать одной из форм безумия. В своей книге [3] он исследует не только аспекты творческого гения, но и его связь с патологией и преступностью. Хотя его идеи нашли подтверждение в некоторых исследованиях, их нельзя считать истинными. Американский нейрофизиолог Джеймс Фэллон, который также длительное время занимался поисками причины психопатии, изучая нейрокриминологию, отсканировал свой собственный мозг и обнаружил, что сам имеет признаки закоренелого преступника, будучи примерным семьянином и успешным ученым [4]. Единственное, ученый отмечает, что в молодости не был примером идеального ребенка, но юность прошла и он так и не стал преступником или, того хуже, маньяком. Несмотря на противоречивость исследований, нейробиология применяется в судебной практике. Одним из примеров прецедентного случая можно считать суд над Гербертом Вайнштейном, которому удалось сократить срок от 25 до 7 лет за жестокое убийство из-за доказанного через МРТ отклонения в способности регулировать свои эмоции [5]. В статье про нейрокриминологию [6] рассмотрено влияние различных биологических факторов на вероятность совершения различных преступлений индивидом, однако, совокупность биологических факторов не позволяет считать человека невиновным за совершение преступлений. В статье, так же упоминается, что недостаточно полагаться только на нейрокриминологию для определения склонности к преступлению. Неотъемлемым фактором влияния на уровень функциональности гена является окружающая среда, что подрывает традиционные аргументы биологического детерминизма. В исследованиях психологических особенностей личности [7] были выдвинуты показатели, которые встречаются у различных видов маньяков для определения более значимых в выявлении серийных убийц: наследственное отягощение, физический статус, особенности раннего развития, психический статус, стиль воспитания в семье, характер работы, проявление социальной дезадаптации в трудовой деятельности и в отношениях с противоположным полом, проявление несексуальных девиаций, увлечения.

Целью данной работы является исследование влияния определенных внешних факторов жизни человека на их предполагаемую склонность к серийным убийствам с использованием нейросетевого подхода. Несмотря на отсутствие практической направленности и этические ограничения, проведенный анализ направлен на более глубокое понимание факторов, которые могут сыграть роль в формировании подобных тенденций.

Для создания нейросети было задействовано 17 входных параметров: отношение к религии, национальность, пол, наличие работы, тюремное заключение, дефекты речи, травмы головы, воровство, был подвержен изнасилованию, родители наркоманы / алкоголики, злоупотребление наркотиками / алкоголем, проблема в школе, жил с детьми, физические дефекты, посещал психолога, была попытка самоубийства, посещал судебно-медицинскую клинику.

В нейросети предусмотрен только один выходной слой – склонность к серийным убийствам. Обратимся к учебному пособию [8], чтобы определить ко-

личество связей и нейронов. Учитывая, что у нас 17 входных параметров и один выходной, объем базы знаний для обучения должен составлять от 134 и выше. Следовательно, объем для валидирующего множества – 13, а для тестового – 7. Далее по теореме Арнольда-Колмогорова – Хехт-Нильсена получаем, что количество синоптических связей должно находиться от 17 до 270. Количество нейронов скрытого слоя для двухслойного персептрона будет располагаться от 1 до 10. Для нейросети была собрана база данных [9], состоящая из трех типов людей: 65 серийных убийц (100% маньяк), 95 знаменитостей, которые не являются убийцами (0% маньяк), 25 людей, совершивших одно убийство (50% маньяк).

Для обучения нейросети была использована нейросеть, написанная на питоне, с использованием библиотеки keras. Также использовался подбор гиперпараметров с использованием randomized search. Лучший результат получилось при наборе: 3 скрытых слоя (нейроны на скрытых слоях: 4, 2, 10), 2000 эпох, функция активации – релу, выходная функция – сигмоида, функция взвешенной суммы – софтлиус.

По результату обучения можно выделить следующие результаты: коэффициент детерминации: 0.996, максимальная ошибка: 0.109, абсолютная ошибка: 0.012, медианная абсолютная ошибка: 0.009, среднеквадратичная ошибка: 0.02.

Далее рассмотрим, как новая модель реагирует на заморозку параметров и проследим как зависит вероятность становления маньяком от различных внешних факторов. Сначала, обратимся к рис. 1, чтобы увидеть, как влияет фактор пережитого насилия в жизни человека. Как можно заметить, в большинстве случаев данный фактор сильно меняет вероятность становления убийцей.




Рис. 1. Влияние фактора насилия

Теперь обратимся к рис. 2, где показано как меняется склонность к убийству относительно фактора нахождения человека в тюрьме. Как можно увидеть, пребывание в тюрьме негативно влияет на формирование личности и увеличивает шанс того, что человек может стать убийцей.




Рис. 2. Влияние фактора пребывания в тюрьме

**Заключительные замечания.** В биографиях одних из самых популярных профайлеров [10], подробно расписано как появилась культура профайлинга в их странах, и как следователи ловили самых известных серийных маньяков. В каждой из книг явно показано, что, несмотря на тяжёлое прошлое преступников, которое узнавалось при допросах, точно выявить типовые особенности становления маньяка, акцентируя внимание только на внешние факторы, невозможно. Количество людей, которые оказываются в подобных ситуациях, как и бедующие маньяки, огромно. Однако они не становятся серийными убийцами. Данная нейросетевая система, или любая подобная, не может достоверно считаться ответом на вопрос – является ли человек маньяком. Подобное исследование описано в статье изучения личности сиренных убийц [11], где так же отмечается, что результирующие данные получились спорными. Как было сказано ранее, по результатам исследований для выявления склонности человека к серийным убийствам необходимо рассматривать как внутренние факторы, так и внешние. К сожалению, никто достоверно не может выявить склонность человека к преступлениям. Разработка подобной системы однозначно будет иметь большие проблемы, связанные с этической стороной вопроса, а также с презумпцией невиновности – пока вина человека не доказана, он считается невиновным. С другой стороны, такая система может повторить судьбу полиграфа и никогда не будет являться доказательством в суде. Единственное применение этой системы в следственной практике может быть только для предположительного сужения круга подозреваемых.

## Библиографический список

1. Новости Каролинского института: Гены связаны с повторными насильственными преступлениями [Электронный ресурс]. Режим доступа: <https://news.ki.se/genes-linked-to-repeated-violent-crime> (Дата обращения 23.11.2023).
2. Adalbert Albrecht, Cesare Lombroso, 1 J. Crim. L. & Criminology 237 (1910) [Электронный ресурс]. Режим доступа: <https://scholarlycommons.law.northwestern.edu/cgi/viewcontent.cgi?referer=https://en.wikipedia.org/&httpsredir=1&article=1023&context=jclc> (Дата обращения 23.11.2023).
3. Cesare Lombroso. The Man of Genius [Электронный ресурс]. Режим доступа: <https://www.gutenberg.org/cache/epub/50539/pg50539-images.html> (Дата обращения 23.11.2023).
4. Techinsider: Нейрокриминология. как устроен мозг маньяков и отличается ли он от нашего [Электронный ресурс]. Режим доступа: <https://www.techinsider.ru/science/233839-kak-ustroen-mozg-manyaka-ubiytsy-my-otlichaemsya-ot-nikh/> (Дата обращения 23.11.2023).
5. Legal Talks: Нейроправо в мире: как болезнь и гормоны могут повлиять на приговор [Электронный ресурс]. Режим доступа: <https://legalacademy.ru/sphere/post/neiropravo-v-mire-kak-bolezn-i-gormony-mogut-povliyat-na-prigovor> (Дата обращения 23.11.2023).

6. Гомонов Н. Д., Труш В. М., Тимохов В. П. Нейрокриминология: прогнозирование и предупреждение насильственной преступности / Новеллы права и правоприменения [Электронный ресурс]. Режим доступа: <https://cyberleninka.ru/article/n/neyrokriminologiya-prognozirovanie-i-preduprezhdenie-nasilstvennoy-prestupnosti/viewer> (Дата обращения 23.11.2023).

7. Логунова О.А., Дворянчиков Н.В. Исследование психологических особенностей личности и поведения серийных сексуальных убийц различных типов [Электронный ресурс] // Психология и право. 2019. Том 9. № 1. С. 54–70. DOI: 10.17759/psylaw.2019090104.

8. Ясницкий Л.Н. Интеллектуальные системы. М.: Издательский «Лаборатория знаний», 2016. – 222 с.

9. The serial killer database [Электронный ресурс]. Режим доступа: <https://killer.cloud/> (Дата обращения 23.11.2023).

10. Квон Ирён, Ко Наму. Кто читает сердце тьмы.: Москва «Экмо», 2023. – 288с.

11. Л. Н. Ясницкий, С. В. Ваулева, Д. Н. Сафонова, Ф. М. Черепанов. Использование методов искусственного интеллекта в изучении личности серийных убийц.: Криминологический журнал Байкальского государственного университета экономики и права. 2015. Т. 9, No 3. С. 423–430.

## NEURAL NETWORK SYSTEM FOR PREDICTING PROPENSITY TO SERIAL MURDERS

***Ponomarev Alexander F.***

Perm State University

Str. Bukireva, 15, Perm, Russia, 614068, [airsunday2001@gmail.com](mailto:airsunday2001@gmail.com)

The article describes the development of a neural network system for determining a person's propensity to serial murder by typical signs. The data for the study is based on the biographies of existing serial killers, as well as ordinary people who could find themselves in similar conditions. The study does not carry a practical nature, in view of the unethical nature of the system being developed.

**Keywords:** artificial intelligence, neural network technologies, forecasting, maniac, serial murders.

УДК 004.032.26

## ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ДАННЫХ ДЛЯ ИССЛЕДОВАНИЯ ХАРАКТЕРИСТИК ПСИХОЛОГИЧЕСКОГО СОСТОЯНИЯ

***Трусова Вероника Александровна***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
[veronikatrusova2003@gmail.com](mailto:veronikatrusova2003@gmail.com)

***Поляков Максим Валентинович***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
[m.v.polyakov@volsu.ru](mailto:m.v.polyakov@volsu.ru)

В данной работе спроектирована и реализована нейронная сеть, предназначенная для прогнозирования ухудшения психологического состояния человека на основе имеющихся данных. По результатам тестирования нейронной сети была получена среднеквадратичная ошибка для заданного набора данных равная 0.68. Показаны возможности практического применения нейросетевых технологий в психологических исследованиях.

**Ключевые слова:** анализ данных, анализ психологического состояния, машинное обучение, нейросетевые технологии

**Введение.** В современном мире объём доступной человеку информации увеличивается с каждым днём. С тем же растёт и её значимость, ведь, анализируя, можно выявлять закономерности с целью принятия обоснованных решений, повышении эффективности работы и предотвращении будущих ошибок [1]. Интеллектуальный анализ данных позволяет автоматизировать значительную часть работы с большим объёмов данным, что ускоряет процесс и снижает число ошибок, связанных с человеческим фактором, которые появляются при расчётах вручную или используя стандартные формулы в табличных процессорах. Существует множество общих методов интеллектуального анализа данных, такие как классификация, кластеризация, регрессия, нейронные сети и т.д. Они используются исследователями, чтобы повысить точность и объективность полученных результатов [2].

Интеллектуальный анализ данных используется уже во многих сферах. Нашёл своё применение он и в психологии, помогая специалистам диагностировать и поддерживать пациентов [3]. Благодаря нему можно выявлять тенденции человека к ухудшению самочувствия, а это в свою очередь влияет на качество повседневной жизни. С поиском закономерностей может помочь нейронная сеть, которая будет рассматривать данные о трудностях с социальным взаимодействием и с преодолением давления или стресса, а также к интересу к работе.

**Постановка задачи и формирование DataSet.** Для моделирования нейронной сети будет использоваться набор данных, в котором содержится информация о глобальном исследовании, проведенном с целью отслеживания тенденций в области психического здоровья. Данные охватывают ряд переменных, таких как уровень стресса, наличие психологических расстройств, субъективного благополучия и использования услуг в области психического здоровья [4].

Для создания нейросетевой системы были выбраны следующие параметры: X1 – пол, X2 – страна, X3 – род деятельности, X4 – самозанятость, X5 – семейная история психологических заболеваний, X6 – лечение, X7 – дни в помещении, X8 – изменения в привычках, X9 – история психического здоровья, X10 – перепады настроения, X11 – интерес к работе, X12 – готовность рассказать о своем здоровье, X13 – осведомленность о вариантах лечения. X14 – растущий стресс, X15 – трудности с преодолением давления/стресса. X16 – социальная слабость. Выходные параметры: Y1 – растущий стресс, Y2 – трудности с преодолением давления/стресса, Y3 – социальная слабость.

В базе данных присутствуют записи, для которых пропущены значения, но так как таких записей пренебрежительно мало (<2%), то они были удалены из выборки. Итоговое множество составило 287162 примеров, которые были перемешаны и разделены на тренировочное и тестовое множества в соотношении 80% и 20%.

## Анализ данных для поиска закономерностей в исходной выборке.

Для исследования взаимосвязи признаков и обнаружения возможных закономерностей, были построены диаграммы рассеяния, на основе которых выведены несколько зависимостей. Например, больше всего трудностей с социальным взаимодействием испытывают студенты и люди, работающие в сфере бизнеса, на что влияет и их отношение к своему роду деятельности (рис. 1).




Рис. 1. Диаграмма рассеяния для исходной выборки данных




Рис. 2. Матрица корреляции для исходной выборки данных

Была построена матрица корреляции между всеми переменными набора данных. Это позволило увидеть, что между данными практически не существу-

ет линейных связей, за исключением историй психологических заболеваний в семье и получения психологической помощи, что является очевидным (рис. 2).

### Проектирование, обучение и тестирование нейронной сети.

Чтобы иметь возможность работать с нелинейными связями между данными и предсказывать ухудшения состояния, была создана нейронная сеть, состоящая из трех полносвязных слоев, на каждом по 128 нейронов (рис. 3). Скрытые слои будут иметь функцию активации ReLU, так как она помогает бороться с исчезающим градиентом, что обеспечивает более быстрое и эффективное обучение нейронных сетей.

Обучение и тестирование нейросети выполнялись в среде разработки Goggle Colab на языке Python с помощью таких библиотек, как Matplotlib, Seaborn, TensorFlow, Keras и Scikit-learn, в которых находятся инструменты для удобного создания нейронов сети, подготовки данных, оценки по разным метрикам моделей и визуализации [5].

За 30 эпох обучения на тренировочных данных, среди которых обучающей выборке отводилось 80% записей, а тренировочной – 20%, нейронная сеть смогла значительно уменьшить потери (рис. 4).




Рис. 3. Схема нейронной сети




Рис. 4. Зависимость потери нейронной сети от эпохи при обучении и валидации



Проведя несколько тестов при разных функциях ошибок, мы можем видеть, что нейронная сеть предсказывает состояние человека достаточно точно и имеет хорошие показатели по различным метрикам (табл.).

Таблица

**Результаты тестирования нейронной сети**

	MAE	MSE	CCE
Потери	0.8480	0.0680	0.2179
Точность	0.7542	0.9495	0.7542
F1	0.7542	0.9499	0.7449

Хороший результат можно увидеть и на матрицах запутанности, где большее число записей попало в поле категории True Positive (рис. 5).




Рис. 5. Матрицы запутанности для растущего стресса и трудности с преодолением давления/стресса

**Заключение.** В данной работе был проведен анализ данных о психологическом состоянии человека с использованием средств языка Python. Спроектирована и разработана искусственная нейронная сеть, позволяющая предсказывать основные характеристики психологического состояния человека с достаточно высокой точностью.

Нейронная сеть для второго набора смогла предсказать ожидаемые значения определенных психологических характеристик, что было бы трудно, основываясь на анализе вручную или с использованием матрицы корреляции и графиков рассеяния, что показывает полезность разработки нейронных сетей для специалистов в области психологии.

## Библиографический список

1. Abdul-Jabbar S. S. et al. Data Analytics and Techniques //ARO-The Scientific Journal of Koya University. – 2022. – V. 10. – №. 2. – P. 45-55.
2. Taherdoost H. Different types of data analysis; data analysis methods and techniques in research projects // International Journal of Academic Research in Management. – 2022. – Vol. 9, no. 1. – P. 1–9.
3. Irshad S., Azmi S., Begum N. Uses of Artificial Intelligence in Psychology // Psychology. – 2022. – Vol. 5, no. 4. – P. 21–30.
4. Kaggle: Mental Health Dataset by Bhavik Jikadara. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com/datasets/bhavikjikadara/mental-health-dataset/data>
5. Advanced Deep Learning for Engineers and Scientists / K. B. Prakash [et al.]. – Springer, 2021. – 285 p.

## INTELLIGENT DATA ANALYSIS FOR THE STUDY OF PSYCHOLOGICAL STATE CHARACTERISTICS

*Trusova Veronika Alexandrovna*

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
[veronikatrusova2003@gmail.com](mailto:veronikatrusova2003@gmail.com)

*Polyakov Maxim Valentinovich*

Volgograd State University,  
Prospect Universitetsky, 100, Volgograd, Russia, 400062  
[m.v.polyakov@volsu.ru](mailto:m.v.polyakov@volsu.ru)

In the modern world, the amount of information available to people is increasing every day. At the same time, its importance grows, because by analysing it, it is possible to identify patterns in order to make informed decisions, improve performance and prevent future errors. And intelligent data analysis helps with this by automating much of the work with large amounts of data. It is already used in many fields. Intelligent data analysis has also found its application in psychology, helping professionals to diagnose and support patients. In this paper a neural network was designed and implemented to predict the deterioration of a person's psychological state on the basis of available data. According to the results of testing the neural network, the RMS error for a given set of data is equal to 0.68. The possibilities of practical application of neural network technologies in psychological researches are shown.

**Keywords:** data analysis, psychological state analysis, machine learning, neural network technologies.

## Секция: Искусственный интеллект и спорт

УДК 004.032.26

### НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ПОБЕДИТЕЛЯ МАТЧА ФУТБОЛЬНОЙ КОМАНДЫ ЛИВЕРПУЛЬ В РАМКАХ АНГЛИЙСКОЙ ПРЕМЬЕР-ЛИГИ

*Корепанов Станислав Александрович*

Национальный исследовательский университет

«Высшая школа экономики»

ВШЭ 614107, Россия, г. Пермь, ул. Бульвар Гагарина, 37а,

sakorepanov@edu.hse.ru

В статье представлено описание разработки системы нейросетевого прогнозирования результатов матчей английской футбольной команды «Ливерпуль». Система показывает достаточно высокую точность прогнозирования. Данная статья опровергает влияние на результат футбольного матча времени начала, места проведения, отношение матча к категории дерби, а также место команды противника в таблице результатов. Выявленные для команды «Ливерпуль» рекомендации соответствуют реальным показателям Английской Премьер-лиги.

**Ключевые слова:** искусственный интеллект, нейросетевые технологии, прогнозирование, футбол, АПЛ.

**Введение.** В экономике существует очень интересная область исследования в экономической теории и теории игр: «Дизайн экономических механизмов» [1]. Эта область представляет собой подход создания механизмов и стимулов для достижения желаемых целей, где игроки действуют рационально, а действия экономических субъектов приводят к решению, оптимальному для функции социального выбора [2]. Один из таких механизмов – настройка ценности очков за победу, ничью и поражение в рамках футбольного матча и чемпионата. Исторически сложилась такая ситуация, что за победу в футбольном матче команде-победителю присуждалось 2 очка, за ничью – по 1 очку каждой команде, за поражение – ничего, 0 очков. Такая система «весов» привела к тому, что футбольные матчи чаще всего становились скучными по причине желания обеих команд не проиграть. Разница между победой и ничьёй оказывалась для команд крайне маленькой в плане результата и набора очков в турнирной таблице, так как зачастую для победы требуется приложить огромное количество усилий, потому что команда, которая проигрывает по ходу игры, будет всегда стараться ответить и сравнять счёт. Во многом поэтому, в 1994 году, было установлено «Правило трёх очков за победу» [3]. Это правило сильно повли-

яло на стратегию игры команд в рамках национальных чемпионатов. Если раньше, стратегию даже самых сильных команд чемпионата для победы в нём вкратце можно было описать так: «сыграть на выезде в ничью, победить дома», то теперь, с установлением данного правила, команды, которые на что-то претендуют (первые 4-6 места национальных чемпионатов выходят на специальные международные турниры с большими призовыми: «Лига чемпионов» и «Лига Европы УЕФА»), обязаны играть активно и всегда стараться победить, почти в каждой игре. Отличный пример такой агрессивной и доминантной команды-победителя – победа в чемпионате Англии команды «Арсенал» под руководством Арсена Венгера в сезоне 2003/2004, которая не проиграла ни одну игру в чемпионате (из 38 матчей одержала 26 побед и только 12 ничьих). Таким образом, данный механизм очень сильно увеличил ценность победы для команды-участника. Побеждая, команда не только могла забрать целых три очка себе, но и отобрать возможные очки у противника (одно или даже три). В связи с описанным выше, в ходе построения модели учитывалась лишь разница между «победой» и «не победой» команды. То есть, ничья и поражение воспринимались как одинаковый выходной признак – «не победа».

Английская премьер лига – известнейшая и престижная футбольная английская лига. В чемпионате играют 20 команд-участников. Всего, в сезоне каждая команда играет 38 матчей – по два матча с каждой другой командой, из них один матч на своем стадионе (home) и один в гостях (away). В рамках работы были оценены и спрогнозированы результаты матчей команды «Ливерпуль», а также выделены наиболее важные признаки, влияющие на результат.

**Постановка задачи.** Данные были взяты с сайта «fbref.com» [4]. Особенности этого ресурса являются: общедоступный доступ к данным, в том числе с помощью технологий вебскрапинга (web scraping) [5] и удобное представление данных в виде таблицы с ключевыми показателями матча. Особенность футбольного матча – очень высокий фактор удачи. Чтобы понизить этот фактор, была проанализирована информация только за последние два сезона перед сезоном 2022/2023, результаты которого мы знаем. Это важно, потому что сезон 2019/2020 Английской Премьер Лиги для многих топ-команд, к которым относятся и «Ливерпуль», оказался переломным и кризисным из-за ситуации с COVID-19 и всеобщим локдауном, а результаты кризиса до сих можно увидеть в том, насколько сильно изменились лидеры турнирной таблицы за несколько лет [6-7]. Логично, что анализ более поздних результатов команды является нерелевантным и неактуальным. Авторами [8-9, 15] были выделены факторы, наиболее сильно влияющие на результат футбольного матча команды: количество ударов по воротам, фактор места встречи (домашнее поле или на выезде), а также метрика ожидаемых голов «xG». Также, в набор входных параметров были включены следующие факторы, анализ которых представлял большой интерес: время встречи, принадлежность матча к классу «дерби» (игра против команды из родного города или с исторически важным, принципиальным соперником), принадлежность к классу «игра против команды из топ-6».

Признаки модели

Обозначение	Разброс значений	Пояснение
X1	0 – до 17:00 1 – после 17:00	время начала матча
X2	от 0 до 5,4	«xG» команды за матч
X3	от 0 до 3,5	«xG» противника за матч
X4	от 1 до 13	удары по воротам, раз
X5	0 – в гостях 1 – дома	место встречи
X6	0 – нет 1 – да	принадлежность матча к классу «дерби»
X7	0 – нет 1 – да	принадлежность матча к классу «игра против команды из топ-6 таблицы»
Y	0 – «не победа» 1 – «победа»	результат матча (результатирующий признак)

Перед созданием модели была выполнена очистка и трансформация данных по методологии Knowledge Discovery in Databases [10] в программном средстве Deductor Studio Academic. Итоговый набор данных состоял из 94 записей. Всё множество записей было разделено на обучающее и тестирующее в соотношении 85% на 15%. В качестве тестового множества были взяты первые 18 матчей команды в сезоне 2022/2023.

**Создание нейронной сети.** Создание структуры, обучение и тестирование нейронной сети было выполнено в программе «Нейросимулятор 5» [11]. Оптимальной оказалась структура с 7 входными нейронами, одним выходным и 5 нейронами на скрытом слое. Средняя относительная ошибка тестирования на тестовом множестве составила 30,9 %.



Рис. 1. Результат тестирования

На рис. 1 можно увидеть график, демонстрирующий разность между ожидаемым результатом (реальным) и рассчитанным нейросетью. Примерно треть результатов оказалась неверной, что для нейросети анализирующей результаты футбольного матча, является типичным результатом.

**Исследование предметной области.** С помощью программы «Нейросимулятор» была вычислена значимость входных параметров.




Рис.к 2. Значимость параметров

На рис. 2 продемонстрированы наиболее значимые параметры – «xG команды», «xG противника» и «удары по воротам». К удивлению, самым значимым параметром является «xG противника». Также, можно сказать, что результаты команды «Ливерпуль» почти не зависят от внеигровых условий: места встречи, противника, времени матча.

Был проведен анализ зависимостей между выбранными тремя наиболее значимыми признаками и результатом матча с помощью метода замораживания [13]. Для метода был выбран нейтральный пример множества, для которого нейросеть не может предсказать результат матча с высокой степенью уверенности.




Рис. 3. Зависимость результата матча от количества ударов по воротам

На рис. 3 представлена зависимость результата матча команды «Ливерпуль» от количества ударов команды по воротам противника. Можно заметить, что количество ударов меньше 5, говорит об однозначном «поражении» или «ничье» команды, в то же время, оптимальное значение ударов по воротам является 14. Это говорит о том, что команда должна стремиться ударить по воротам противника как минимум 14 раз за матч для надежды на успех. В реальности уже подсчитано, что среднее соотношение голов в зависимости от ударов по воротам составляет примерно 18-30% в зависимости от команды [14]. Таким образом, несложно подсчитать среднее ожидаемое количество голов команды, если она ударит по воротам хотя бы 14 раз за матч: 3,5 гола. Это достаточный показатель для победы в абсолютном большинстве матчей.




Рис. 4. Зависимость результата матча от метрики «xG» команды Ливерпуль за матч

На рис. 4 представлена зависимость результата матча команды «Ливерпуль» от суммарной метрики «xG» в данном матче. Примечательна отметка в 2,5 потенциальных голов за матч, как обеспечивающая победу команды практически на 100%. Команде следует стремиться к такому показателю. Также, можно сделать вывод, что показатель «xG», меньше чем 1, свидетельствует о проблемах команды в матче: поражение или ничья.




Рис. 5. Зависимость результата матча от метрики «xG» противника команды Ливерпуль за матч

На рис. 5 можно наблюдать зависимость результата от показателя «xG» противника. Как видно из графика, в случае допущения командой Ливерпуль создания противником менее 1 опасного момента, ведущего к голу, означает победу с большой долей вероятности. В случае, если метрика «xG» противника равна или больше 2,2, команду ждёт неудовлетворительный результат. Это означает, что защита команды «Ливерпуль» может позволить противнику создание в среднем не более 2 опасных, «стоцентных» моментов у своих ворот.

**Заключение.** Были проанализированы матчи английской команды Ливерпуль за сезоны 2020/2021 и 2021/2022, на их основе были спрогнозированы результаты матчей команды для первой половины сезона 2022/2023. Точность модели составила 33,2%. Была опровергнута гипотеза о значимости следующих параметров на результат матча: «время начала матча», «класс матча – дерби», «игра против команды из топ-6 таблицы» и «место встречи команд». Также, были предложены рекомендации для команды, связанные с минимально необходимым для победы количеством ударов по воротам (14), оптимальными показателями «xG» команды (2,5) и противника (0,5).

Дальнейшее совершенствование данной работы предполагает использование других предсказательных моделей машинного обучения и увеличения количества записей в датасете, например, включением в анализ матчей не только АПЛ, но и других турниров, в которых участвовала команда в анализируемые сезоны.

### Библиографический список

1. Теория экономических механизмов // ПостНаука URL: <https://postnauka.org/talks/9281> (дата обращения: 10.03.2024).
2. Савватеев А.В., Филатов А.Ю. Занимательная экономика. – М.: АСТ, 2023. – 352 с.
3. 13 главных изменений в правилах футбола за последние 50 лет // Чемпионат URL: <https://www.championat.com/football/article-3458661-kak-menjalis-futbolnye-pravila.html> (дата обращения: 10.03.2024).
4. 2021-2022 Manchester City Stats (Premier League) // fbref URL: <https://fbref.com/en/squads/b8fd03ef/2021-2022/Manchester-City-Stats> (дата обращения: 10.03.2024).
5. Web Scraping // Habr URL: <https://habr.com/ru/articles/488720/> (дата обращения: 17.03.2024).
6. 2018-2019 Premier League Stats // fbref URL: <https://fbref.com/en/comps/9/2018-2019/2018-2019-Premier-League-Stats> (дата обращения: 16.03.2024).
7. 2022-2023 Premier League Stats // fbref URL: <https://fbref.com/en/comps/9/2022-2023/2022-2023-Premier-League-Stats> (дата обращения: 15.03.2024).
8. Манукян А.А., Катышев П.К. ВЫЯВЛЕНИЕ И ОЦЕНКА ФАКТОРОВ, ВЛИЯЮЩИХ НА РЕЗУЛЬТАТ ФУТБОЛЬНОГО МАТЧА // Регион и мир. 2019. №5. URL: <https://cyberleninka.ru/article/n/vyyavlenie-i-otsenka-faktorov-vliyayuschih-na-rezultat-futbolnogo-matcha> (дата обращения: 16.03.2024).
9. Lepschy H., Wäsche H., Woll A. Success factors in football: an analysis of the German Bundesliga // International Journal of Performance Analysis in Sport. – 2020. – №20. – С. 150-164.
10. Обнаружение знаний в базах данных (Knowledge Discovery in Databases) // Loginom URL: <https://wiki.loginom.ru/articles/knowledge-discovery-in-databases.html> (дата обращения: 16.03.2024).
11. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RU2014612546. Заявка № 2014610341 от 15.01.2014.
12. Ясницкий Л.Н. Введение в искусственный интеллект. – М.: Издательский центр «Академия», 2010. – 176 с.
13. 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. С. 985.
14. Статистика ударов // Советский спорт URL: <https://www.sovsport.ru/football/articles/272715-statistika-udarov?ysclid=lu8hb97mqsl60888607> (дата обращения: 23.03.2024).
15. 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.
16. Ясницкий Л.Н., Киросова А.В., Ратегова А.В., Черепанов Ф.М. Методика нейросетевого прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике. Вестник Пермского университета. Математика. Механика. Информатика. 2014. № 3 (26). С. 90-97.



# NEURAL NETWORK SYSTEM FOR PREDICTING THE WINNER OF THE LIVERPOOL F.C. FOOTBALL TEAM MATCH IN THE ENGLISH PREMIER LEAGUE

*Korepanov Stanislav A.*

National Research University Higher School of Economics  
Studencheskaya Street, 38, Perm, Russia, 614068,  
sakorepanov@edu.hse.ru

This article describes the development of a neural network forecasting system for the results of matches of the English football team Liverpool FC. The system shows sufficient forecasting accuracy. This article refutes the impact on the result of a football match of the start time, venue, belonging of the match to the derby category, as well as the place of the opposing team in the results table. The recommendations identified for the Liverpool team correspond to the real indicators of the English Premier League.

**Keywords:** artificial intelligence, neural network, prediction, soccer, football, EPL.

УДК 004.032.26

## НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ РЕЗУЛЬТАТОВ КОМАНД РОССИЙСКОЙ ПРЕМЬЕР-ЛИГИ В КОНЦЕ СЕЗОНА

*Пачин Андрей Дмитриевич*

Национальный исследовательский университет  
«Высшая школа экономики»  
ВШЭ 614107, Россия, г. Пермь, ул. Бульвар Гагарина, 37а,  
e-mail: andreypachin2014@gmail.com

В статье описаны этапы разработки нейросетевой системы для прогнозирования расположения футбольных клубов Российской Премьер-Лиги (РПЛ). Система позволяет предсказать позицию клубов в итоговой турнирной таблице на основании результатов первой половины сезона. Разработанная интеллектуальная система позволила провести исследование предметной области и выявить закономерности, влияющие на итоговый результат.

**Ключевые слова:** искусственный интеллект, нейросетевые технологии, прогнозирование, футбол, РПЛ, Российская Премьер-Лига.

**Введение.** Статистические данные стали неотъемлемой частью в спорте, в частности в футболе. С их помощью тренерский штаб футбольного клуба может формировать стратегию, касающуюся подбора игроков, и готовить тактики к предстоящим матчам. В настоящее время в футбол внедряются технологии, упрощающие сбор и анализ информации о действиях игроков на поле. Оттого обработка и интерпретация полученных данных значительным образом может повлиять на будущие результаты клубов. Для этого важно иметь инструмент, позволяющий выявлять закономерности, которая может в большинстве случаев предоставить верный прогноз. До недавнего времени турнирная таблица делилась на три зоны: зона еврокубков, середина таблицы, где клубы лишь сохраня-

ли свое место в РПЛ, и зона вылета, означающая, что клубы на последних местах либо покидают лигу, либо борются за нахождение в РПЛ с клубами из нижнего дивизиона. Знание об итоговых результатах могла использоваться для привлечения спонсоров и повышения как статуса клуба, так и его привлекательности для игроков. Как показал опыт Пермской научной школы искусственного интеллекта, например, [1-3], правильно натренированная нейросетевая система может добиться успешности большей части прогнозов.

При анализе литературных источников выяснилось, что в качестве событий отдают предпочтение личным встречам, нежели конечным итогам чемпионатов. Клубный футбол в национальных чемпионатах также отличается от международных клубных чемпионатов и соревнований национальных сборных. Так, в качестве параметров не могут быть указаны результаты жеребьевки и сыгранных групповых матчей, поскольку таких событий нет в РПЛ. В работах Бутиной Д.В. [4-5] рассмотрены национальные лиги Италии и Германии. Входные параметры отличаются в работах: при построении модели для «Бундеслиги» выбраны физические показатели игроков и результаты команды в сезоне; при рассмотрении «Серии А» были выбраны стоимостные характеристики.

Основная цель настоящей работы заключается в сборе множества публичных данных о клубах и их матчах, а также создание и обучение нейросетевой модели на этих данных. Конечным результатом должна быть нейросетевая система, способная итоговую зону в турнирной таблице в больше, чем 70% случаев.

**Постановка задачи.** Для создания нейронной сети были выбраны такие параметры, как:  $X_1$  – среднее количество забитых мячей за матч (количество голов за сезон/количество матчей),  $X_2$  – среднее количество пропущенных мячей за матч (количество пропущенных мячей за сезон/количество матчей),  $X_3$  – процент побед в гостевых матчах (от числа всех игр),  $X_4$  – процент побед в домашних матчах (от числа всех игр),  $X_5$  – стоимость состава,  $X_6$  – средний возраст состава,  $X_7$  – среднее количество ударов по воротам за игру,  $X_8$  – позиция в таблице по итогам прошлого сезона,  $X_9$  – процент ничейных результатов,  $X_{10}$  – средняя стоимость вратарей,  $X_{11}$  – средняя стоимость игроков защиты,  $X_{12}$  – средняя стоимость полузащитников,  $X_{13}$  – средняя стоимость игроков атаки. Выходной параметр – позиция по итогам текущего сезона.

Обучающее множество было собрано с вручную с интернет-ресурсов. Объем итогового множества включает в себя 106 примеров. Собранные данные были разделены на обучающие, валидационные и тестовые в отношении 82/14/8 соответственно. Большая часть данных была собрана с интернет-ресурсов [6, 9-10].

**Проектирование нейронной сети.** Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [7] по методике [8]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет тринадцать входных нейронов, один выходной и один скрытый слой с тремя нейронами. Активационная функция входного слоя – синус, скрытого слоя – тангенс гиперболический, выходного – линейная.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 8 примеров. Среднеквадратичная ошибка тестирования составила примерно 0,25, что означает четверть спрогнозированных результатов ошибочна. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью результатами клубов по итогу соревнования. На ней можно увидеть, что четверть прогнозов неверна. Однако это вызвано тем, что значения параметров, характеризующих игровые показатели, для тестового множества взяты за половину сезона. В футболе может, как и в других дисциплинах, команда во вторую половину чемпионата может демонстрировать как спад, так и подъем качества выступлений.




Рис. 1. Результат тестирования нейронной сети на данных за первую половину сезона

На рис. 2 видно, что точность прогнозов повысилась. Единственный пример, в котором нейросеть выдала ошибку, в действительности находился на 11 месте в таблице, которое отделено одной позицией от зоны вылета. Среднеквадратичная ошибка тестирования уже снизилась примерно до 0,126. Примеры 5 на рис. 1 и 4 на рис. 2 демонстрируют результаты клуба «Амкар» за первую половину сезона и весь сезон соответственно. Сравнение прогнозируемых результатов дает подтверждение тому, что выступления команд в разных половинах сезона может отличаться. Так, на замену хорошим выступлениям «Амкара» в первой части турнира, пришел спад во второй ее половине.

Для сравнения точности прогнозов была смоделирована аналогичная нейронная сеть при помощи языка Python и библиотеки Keras. Чтобы сравнение было объективным, обеим моделям (построенным в Нейросимуляторе и в Python) активационная функция входных нейронов была заменена на гиперболический тангенс. Это вызвано тем, что стандартный набор инструментов Keras не подразумевает использование синуса как активационной функции.

При построении модели с помощью Python обучающий и тестовый наборы данных были стандартизированы. При обучении к тому же использовалась регуляризация.




Рис. 2. Результат тестирования нейронной сети на данных за весь сезон

Построенная нейросеть с помощью инструментов Python имела график функции потерь, изображенный на рис. 3. На рис. 4 же изображен график функции потерь для модели, построенной в Нейросимуляторе. Можно заметить, что у модели, построенной в Python, функция потерь принимала меньшие значения, чем функция у второй модели.




Рис. 3. График функции ошибок модели (Keras)




Рис. 4. График функции ошибок модели (Нейросимулятор)

На рис. 5 и 2 видно разницу в ошибках прогнозов двух моделей. Для тестов использовались одинаковые наборы данных. Точность прогнозов у второй модели (рис. 2) выше. Это же подтвердило и вычисленное среднеквадратичное отклонение (MSE) (табл.).




Рис. 5. Сравнение фактических и прогнозируемых результатов (Keras)

Также качество моделей можно оценить при помощи коэффициента детерминации, то есть оценку качества зависимости выходного значения от вход-

ных параметров. Сеть, построенная с помощью Нейросимулятора, продемонстрировала лучший результат, что можно увидеть в табл.

Таблица

**Сравнение среднеквадратичных ошибок**

	Среднеквадратичная ошибка (MSE)	Коэффициент детерминации (R2)
Keras	0,1749	0,8601
Нейросимулятор	0,1257	0,8997

**Исследование предметной области.** Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рис. 7.

Как видно из рис. 3, наиболее значимыми параметрами являются проценты домашних и гостевых побед, причем значение домашних выше, чем гостевых. Влияние среднего количества ударов по воротам за игру означает, что атакующий потенциал команды важен. Но все же не он не определяет результаты команды, ибо не каждый удар по воротам заканчивается голом. Обычно в спорте стоимость состава демонстрирует качество выступающих за клуб игроков, однако этот параметр не всегда является верным индикатором. Причины тому разные, одной из них, например, является значимость клуба и лиг, в которых клуб выступает, для игроков. Средние стоимости игроков на разных позициях практически не влияют на итоговый результат.

Далее было проведено исследование полученных зависимостей между входными параметрами и результатами прогнозирования. Исследование производилось с помощью метода «замораживания» [1-3, 8], суть которого заключается в варьировании значения одного параметра и фиксировании значений всех других параметров. Для этой цели был отобран пример 2 с рис. 2, на котором нейронная сеть ошиблась. В действительности игровые и стоимостные параметры позволяют отнести рассматриваемый клуб в зону вылета, однако клуб находится на 11 месте. Значения параметров взяты в контексте всего сезона.




Рис. 7. Значимость входных параметров нейросетевой модели

На рис. 8 показан график зависимости итоговой позиции от побед в домашних встречах. Чем выше процент побед, тем более высокую позицию прогнозирует нейросеть. В действительности редко какая-либо из команд за сезон способна приблизиться к показателю равному 40%. Поэтому следует обратить внимание на прогнозы для 30% и 35%. Относительно собранных статистических данных прогнозы для выделенных значений являются адекватными.



Рис. 8. Зависимость прогнозируемого победителя от процента побед в домашних матчах



Рис. 9. Зависимость прогнозируемого победителя от процента побед в гостевых матчах

На рис. 9 продемонстрирована зависимость позиции от процента побед в гостевых встречах. Можно заметить, что итог гостевых встреч сильнее влияет на результат клуба в сезоне.

На рис. 10 изображен график зависимости позиции от среднего количества ударов. Как видно из графика, изменение этого параметра не дает сильный прирост к значению выходного параметра. В статистике за рассматриваемый период отметка в 18 ударов преодолевалась лишь единожды, и даже с этим показателем нейронная сеть не дает клубу место выше 9-12.

На рис. 11 продемонстрирована зависимость результата от стоимости всех игроков в составе. Как видно из графика, увеличение этого критерия практически не влияет на позицию в турнирной таблице. Это объясняется тем, что ценовые характеристики по значимости уступают игровым показателям. Также в генеральной совокупности заметно, что общая стоимость глобально не определяет позицию, не считая клубов со сравнительно большими бюджетами, чем у остальных участников турнира. На самом деле лишь одна-две команды в собранном наборе данных смогли иметь игроков на сумму более 150 млн евро, поэтому все значения выше этой отметки можно считать аномальными.

На рис. 12 продемонстрирована зависимость прогнозируемого результата от среднего количества пропущенных мячей. Чем меньше команда пропускает мячей, тем более высокую позицию она может занимать.



Рис. 10. Зависимость положения в таблице от среднего количества ударов за игру



Рис. 11. Зависимость прогнозируемого победителя от победителя предыдущей встречи



Рис. 12. Зависимость прогнозируемого победителя от процента ничейных матчей

**Закключение.** Построена система нейросетевого прогнозирования расположения клубов Российской Премьер-Лиги. Спроектированная нейросетевая модель учитывает 13 параметров: среднее количество забитых мячей за матч, среднее количество пропущенных мячей за матч, процент побед в гостевых матчах, процент побед в домашних матчах, стоимость состава, средний возраст состава, среднее количество ударов по воротам за игру, позиция в таблице по итогам прошлого сезона, процент ничейных результатов, средняя стоимость вратарей, средняя стоимость игроков защиты, средняя стоимость полузащитников, средняя стоимость игроков атаки. Выходной параметр – позиция по итогам текущего сезона. Методом сценарного прогнозирования построены графики зависимостей прогнозируемого победителя матча от изменения входных параметров. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать победителя матчей. Данный набор параметров может быть изменен для повышения точности прогнозов.

### Библиографический список

1. 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. С. 985.
2. Ясницкий Л.Н., Vnukova O.V. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта // Современные проблемы науки и образования. 2014. № 1. С. 189.

3. 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. С. 624.
4. Бутина Д. В., Ясницкий Л. Н. Нейросетевая система прогнозирования результатов сезона итальянской футбольной лиги "Серия А" // Вестник Пермского университета. Математика. Механика. Информатика. 2023. Вып. 1(60). С. 84–92.
5. 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.
6. Soccer 365. URL: <http://soccer365.ru/> (дата обращения: 08.03.2024).
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
8. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
9. Transfermarkt. URL: <https://www.transfermarkt.world/> (дата обращения: 08.03.2024).
10. WhoScored. URL: <https://ru.whoscored.com/> (дата обращения: 08.03.2024).

## NEURAL NETWORK SYSTEM FOR PREDICTING THE ITALIAN FOOTBALL LEGA "SERIE A" SEASON RESULTS

*Pachin Andrey D.*

National Research University Higher School of Economics  
Studencheskaya Street, 38, Perm, Russia, 614068, andreypachin2014@gmail.com

The paper describes the stages of development of a neural network system for predicting the position of football clubs in the Russian Premier League (RPL). The system allows predicting the position of clubs in the final standings based on the results of the first half of the season. The developed intellectual system allowed to conduct a study of the subject area and identify patterns affecting the final result.

**Keywords:** artificial intelligence, neural network technologies, forecasting, football, RPL, Russian Premier League.

УДК 004.032.26

## СОЗДАНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ИСХОДА ПОЕДИНКА В СМЕШАННЫХ ЕДИНОБОРСТВАХ

*Решетников Михаил Андреевич*

Пермский государственный национальный исследовательский университет,  
ПМИ. 614068, Россия, г. Пермь, ул. Букирева, 15,  
[Reshetnikov-mikhail@yandex.ru](mailto:Reshetnikov-mikhail@yandex.ru)

Разработанная нейронная система предназначена для прогнозирования победителя поединка на основе статистических показателей предыдущих результатов. Предметная область – спорт. С помощью разработанной интеллектуальной системы проведено исследование предметной области, выявлены закономерности, имеющие практическое значение



**Ключевые слова:** нейросетевая модель нейросеть, UFC, прогнозирование результатов, обучение сети, смешанные единоборства.

**Введение.** Тема спорта очень невероятно актуальна и интересна. На тему спорта было сделано множество нейросетевых проектов, которыми я вдохновлялся [6, 8, 9, ~~Ошибка! Источник ссылки не найден.~~, 10]. ММА – самый быстро развивающийся спорт в мире. Некоторые люди нашли возможность заработать на этом, предугадывая исходы поединков. С увеличением популярности данного вида спорта, к нему стал увеличиваться интерес как со стороны спортивных аналитиков, пытающихся давать максимально проходимые прогнозы, так и со стороны букмекерских контор, для которых, в свою очередь, верный подсчёт коэффициентов на поединок является залогом прибыли. В связи с этим целью является разработка нейросетевой модели для предсказания исхода боя.

При анализе литературных источников выяснилось, что над такими моделями уже велись работы. Данная модель может стать помощником, как для букмекерских компаний, так и для спортивных аналитиков.

**Описание модели.** Сеть создана на основе программного инструмента Нейросимулятор-5.0 [0], имеет шесть ( $X_i$ ) входных параметров и один ( $X_y$ ) выходной.

**Методика прогнозирования.** Для создания нейросетевой системы были выбраны следующие параметры:  $X_1$  – Разница общего количества раундов,  $X_2$  – Разница роста,  $X_3$  – Разница размаха рук,  $X_4$  – Разница возраста,  $X_5$  – Ставка на бойца 1,  $X_6$  – Ставка на бойца 2. Выходной параметр – Вероятность победы бойца.

Множество для обучения было собранно с интернет-ресурса Kaggle[5], содержащее большое количество дата-сетов. Обучение нейросети было произведено с помощью программы “Нейросимулятор 5” [0]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет 6 входных нейронов, один скрытый слой, на котором 3 нейрона, один выходной слой. Персептрон представлен на рис. 1.

Данные для обучения и тестирования основаны на информации с сайта. Всего собрано 182 примеров, 150 ( $Q$ ) из которых были использованы для обучения сети. По формуле, являющейся следствием из теоремы Арнольда – Колмогорова [3], был найден диапазон для количества нейронов на скрытом слое.

В этой формуле:  $N_y$  – количество выходных нейронов,  $N_x$  – количество входных нейронов,  $Q$  – число элементов множества обучающих примеров,  $N_w$  – необходимое число синоптических связей. Полученная оценка:  $18,24 \leq N_w \leq 182$ .

Далее находим оценку для  $N$  (количество нейронов на скрытом слое):  $2,60 \leq N \leq 26,00$ . В качестве оптимального варианта выбрано  $N=3$ .

**Проверка модели.** Сеть была протестирована на 16 примерах. Результаты проверки работы нейросети представлены на рис. 1.




Рис. 1. Сопоставление ожидаемых и полученных результатов

**Значимость параметров.** Построенная гистограмма, изображенная на рис. 2, характеризует значимость (степень влияния на результат) входных параметров. Как видно из рисунка, наиболее значимым параметром является ставка на победу первого бойца. Остальные параметры незначительно отличаются по уровню значимости.




Рис. 2. Гистограмма распределения значимости входных параметров

**Дальнейшее исследование сети.** Исследование производилось с помощью метода «замораживания» [0,4,5], суть которого заключается в варьировании значения одного параметра и фиксировании значений всех других параметров.

Влияние разницы общего количества раундов проведенных за карьеру на исход боя. Был произведен прогноз на 6 примерах с различными данными. Данные примеры приведены в табл. 3, где входной параметр X1 отвечает за количество проведенных раундов в карьере бойца.

Таблица

**Примеры для исследования влияния ставки на бойца 1 на вероятность победы 1-го бойца в поединке**

Разница общего количества раундов	Разница роста	Разница размаха рук	Разница возраста	Ставка на бойца 1	Ставка на бойца 2
-11	-15,24	-17,78	-5	435	-570
-11	-15,24	-17,78	-5	100	-570
-11	-15,24	-17,78	-5	-200	-570
-11	-15,24	-17,78	-5	-500	-570
-11	-15,24	-17,78	-5	-1000	-570
-11	-15,24	-17,78	-5	-1500	-570

На рис. 3 показано влияние ставки на бойца 1, на вероятность его победы в бою. Исходя из графика, можно сделать вывод, что чем меньше ставка на бойца 1, тем выше вероятность его победы.



Рис. 3. График, иллюстрирующий зависимость вероятности выигрыша 1-го бойца от размера ставки на него

На рис. 4 показано влияние разницы количества раундов бойцов за карьеру на вероятность победы 1 бойца в бою. Исходя из графика, можно сделать вывод, что чем больше боев провел боец 1, чем боец 2, тем выше вероятность победы 1 бойца.



Рис. 4. График, иллюстрирующий зависимость вероятности выигрыша 1-го бойца от разницы раундов бойцов за карьеру

На рис. 5 изображено влияние разницы возраста бойцов на победу 1 бойца в бою. Исходя из графика, можно сделать вывод, что чем старше боец 1, тем выше вероятность его победы.



Рис. 5. График, иллюстрирующий зависимость вероятности выигрыша 1-го бойца от разницы в возрасте бойцов за карьеру

**Работа с Keras.** Проведены сравнения моделей разработанной в нейросимуляторе и Keras. Данные были взяты из работы в Нейросимуляторе. Набор данных также, успешно обучился.




Рис. 6. Сопоставление ожидаемых и полученных результатов, в Keras.



Рис. 7. График, иллюстрирующий зависимость вероятности выигрыша 1-го бойца от размера ставки на него, в Keras

**Сравнение коэффициента детерминации.** Коэффициент детерминации в Keras, получился  $r = 0.75$ , что является нормальным результатом, адекватной сети. Коэффициент детерминации сети из Нейросимулятора, был высчитан при помощи работы с Microsoft Excel,  $r = 0,77$ . Из этого можно сделать вывод, что сеть из Нейросимулятора дает лучшие результаты, чем сеть, обученная в Keras.

**Заключение.** Созданная нейросетевая модель позволяет спрогнозировать поединка в ММА. Данная модель учитывает физические характеристики и историю боев, влияющие на исход боя. Методом сценарного прогнозирования построены графики зависимостей шансов на победу бойца от некоторых входных данных. Модель может быть использована для спортивной аналитики, расчёта котировок коэффициентов в букмекерских конторах. Модель работает адекватно, может быть использована для прогнозирования успеха бойца, такая информация может быть полезна как для тренеров, так и для букмекерских контор.

## 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. Ultimate UFC Dataset [Электронный ресурс]. – URL: <https://www.kaggle.com/mdabbert/ultimate-ufc-dataset>
6. 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. С. 985; URL: <http://www.scienceeducation.ru/113-11206>
7. Yuan Tian Predict [https://medium.com/@yuan\\_tian/predict-ufc-fights-with-deep-learning-ii-data-collection-and-implementation-in-pytorch-ff7a95062554](https://medium.com/@yuan_tian/predict-ufc-fights-with-deep-learning-ii-data-collection-and-implementation-in-pytorch-ff7a95062554) // UFC Fights with Deep Learning II – Data collection and implementation in PyTorch.
8. 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. С. 624.
9. Ясницкий Л.Н., Vnukova O.V. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта // Современные проблемы науки и образования. 2014. № 1. С. 189.
10. 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..
11. Towards Data Science. – URL: <https://towardsdatascience.com/predicting-ufcbouts-with-dnn-classifier-f955e9abe6c6>
12. UFC-Data [Электронный ресурс]. – URL: <https://github.com/ktonthat/UFCdata>

## CREATING A NEURAL NETWORK MODEL FOR PREDICTING THE OUTCOME OF A MIXED MARTIAL ARTS MATCH

**Reshetnikov Mikhail Andreevich**

Perm State University, PMI. 614068, Russia, Perm, Bukireva str., 15,  
Reshetnikov-mikhail@yandex.ru

The developed neural system is designed to predict the winner of a duel based on statistical indicators of previous results. The subject area is sports. With the help of the developed intellectual system, a study of the subject area was carried out, patterns of practical importance were identified

**Keywords:** neural network model neural network, UFC, prediction of results, network training, mixed martial arts.

## НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ РЕЗУЛЬТАТОВ КУБКА МИРА ПО БИАТЛОНУ

*Россихина Евгения Михайловна*

Пермский государственный национальный исследовательский университет,  
ПМИ. 614068, Россия, г. Пермь, ул. Букирева, 15,  
zheniarossihina@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования результатов спортсмена в различных гонках Кубка мира по биатлону. Система позволяет определить примерное место, которое займет биатлонист в соревновании с учетом его физических и психологических показателей.

**Ключевые слова:** биатлон, искусственный интеллект, нейросетевые технологии, прогнозирование, процентовка стрельбы, скорострельность, скорость, спорт.

**Введение.** В последнее время в спортивной науке обретают удачное применение нейросетевые технологии. Их возможно применять с целью прогнозирования результатов, отбора более эффективных спортсменов, раскрытия важных условий в программе подготовки к состязаниям. Результативность применения искусственного интеллекта при моделировании итогов состязаний была показана в трудах российских исследователей [1-3,11]. Таким образом, в одном из трудов [11], опубликованном в 2013 г., был показан подтвердившийся в дальнейшем прогноз места в частном командном зачёте российских спортсменов в зимней Олимпиаде-2014. При формировании нейросетевых систем авторы трудов [1-3] принимали во внимание не только физиологические и психические показатели спортсменов, а также их условия жизни (страна, народ, вероисповедание и т.д.).

Это изучение нацелено на создание системы прогнозирования результатов интернациональных состязаний по биатлону. Главная задача данной работы состоит в сборе множества касательно действующих спортсменов, и, кроме того, создание и обучение нейросетевой модели на этих сведениях.

В результате анализа литературных источников [1-3, 9-11] и собственного опыта был выбран следующий набор показателей: X1 – вид гонки, X2 – место по скорости за предыдущую гонку, X3 – место по скорострельности за предыдущую гонку, X4 – процентовка стрельбы на момент начала гонки, X5 – наличие коронавирусной инфекции у спортсмена в 2020-2021 гг., X6 – пол, X7 – возраст (лет), X8 – страна. Выходной параметр D1 – итоговый результат.

Параметр «Вид гонки» был закодирован: 0 – индивидуальная гонка, 1 – спринт. Были отобраны именно эти виды гонок, так как они имеют наибольшее количество участников и не зависят от результатов других гонок. Для кодирования параметра «Наличие коронавирусной инфекции у спортсмена в 2020-2021 гг.» использовались следующие обозначения: 0 – спортсмен переболел, 1 – спортсмен не болел. Параметр «Страна» также был закодирован: 0 – слабые страны, 1 – средние, 2 – сильные. Деление стран по категориям происходило по усредненным результатам Кубка Нации 2020/2021 [4-5]. В число сильных стран

вошли страны с 1 по 9 место, в число средних – с 9 по 17, остальные – в число слабых. Другие параметры являются числовыми, поэтому для них кодировка не потребовалась.

Множество входных данных о результатах спортсменов было собрано с сайта IBU [6]. Объем итогового множества включает в себя 470 примеров. Данное множество было разделено на обучающее, тестирующее и подтверждающее в соотношении 80%, 15% и 5% соответственно. Собранные данные охватывают серию международных соревнований 2020-2021 года.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [7] по методике [8]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет восемь входных нейронов, один выходной и один скрытый слой с четырьмя нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось подтверждающее множество, состоящее из 20 примеров. Средняя ошибка тестирования составила 11.22%, что можно считать приемлемым результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью итоговым результатом случайно отобранных 20 спортсменов из подтверждающего множества.



Рис. 1. Результат тестирования нейронной сети

Из результатов, изображенных на рис. 1, можно сделать вывод об адекватной работе спроектированной нейронной сети.

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5» [7], результат отображен на рис. 2.




Рис. 2. Значимость входных параметров нейросетевой модели

Как видно из рис. 2, наиболее значимыми являются «Место по скорости», «Процентовка стрельбы» и «Вид гонки». Значительно меньшее влияние оказывают такие параметры как «Скорострельность», «Пол», «Наличие коронавирусной инфекции», «Страна» и «Возраст».

Далее было проведено исследование итоговых результатов спортсменов. Исследование производилось с помощью метода «замораживания» [8], 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 был отобран спортсмен, информация о параметрах которого отражена в табл.

Таблица

**Характеристики спортсмена, выбранного для исследования**

Входные параметры	Расшифровка	Характеристики
X2	Место по скорости за предыдущую гонку	47
X3	Место по скорострельности за предыдущую гонку	3
X4	Процентовка стрельбы на момент начала гонки	80
X5	Наличие коронавирусной инфекции в 2020-2021 гг.	1
X6	Пол (0 – м, 1 – ж)	0
X7	Возраст	28
X8	Страна (2 – сильные, 1 – средние, 0 – слабые)	2

На рис. 3-4 показаны графики зависимости итогового результата от места по скорости и скорострельности за предыдущую гонку соответственно. Как следует из графиков, вне зависимости от вида гонки, более высокое место по скорости и скорострельности приводит к более высокому результату.




Рис. 3. Зависимость итогового результата от места по скорости за предыдущую гонку




Рис. 4. Зависимость итогового результата от места по скорострельности



На рис. 5 продемонстрирован график зависимости результата биатлониста от процентовки стрельбы на момент начала гонки. По полученному графику можно заметить, что при увеличении процентовки стрельбы улучшается итоговый результат.

На рис. 6 представлен график зависимости итогового результата от возраста спортсмена. Как показывает график, этот параметр почти никак не влияет на итоговый результат, но можно заметить, что более опытный спортсмен лучше преодолевает спринтерскую гонку, чем молодой. Скорее всего это связано с тем, что с возрастом у спортсмена формируется более устойчивая нервная система, а значит и улучшается качество стрельбы, что крайне важно в гонках на короткие дистанции.

Полученные результаты исследований не противоречат реальности, что подтверждает, что спроектированную нейронную сеть можно считать пригодной для прогнозирования итогового результата спортсменов.




Рис. 5. Зависимость итогового результата от процентовки стрельбы на момент начала гонки




Рис. 6. Зависимость итогового результата от возраста

**Заключение.** Выстроена система нейросетевого прогнозирования результатов интернациональных состязаний по биатлону. Спроектированная нейросетевая модель предусматривает две группы характеристик, оказывающих большее влияние на окончательный результат спортсмена: физиологические и психические. Проведен анализ окончательных результатов спортсмена. Методом сценарного прогнозирования построены графики связей окончательного результата с местом по скорости, места по скорострельности за предшествующую гонку, процентовки стрельбы, а также возраст. Технология нейросетевого моделирования способна также быть использована с целью извлечения полезных

советов с целью усовершенствования итогов спортсмена, занимающегося этим видом спорта.

### Библиографический список

1. 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: 22.03.2021).
2. Ясницкий Л.Н., Киросова 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.
3. 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](http://www.science-education.ru/118-14423) (дата обращения: 22.03.2021).
4. Olympteka.ru [Электронный ресурс]. – URL: <https://olympteka.ru/sport/biathlon/rating/355.html>
5. Olympteka.ru [Электронный ресурс]. – URL: <https://olympteka.ru/sport/biathlon/rating/356.html>
6. International Biathlon Union – IBU [Электронный ресурс]. – URL: <https://www.biathlonworld.com/calendar/#/event-2>
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
8. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
9. Skattebo Ø., Losnegard T. Variability, Predictability, and Race Factors Affecting Performance in Elite Biathlon // International Journal of Sports Physiology and Performance. – vol. 13 – № 3. – P. 313-319; URL: <https://journals.humankinetics.com/view/journals/ijsp/13/3/article-p313.xml>
10. Laaksonen M.S., Finkenzeller T., Holmberg H.-C., Sattlecker G. The influence of physiobiomechanical parameters, technical aspects of shooting, and psychophysiological factors on biathlon performance // Journal of Sport and Health Science. – October 2018. – vol. 7 – № 4 – P. 394-404; URL: <https://www.sciencedirect.com/science/article/pii/S2095254618300760#!>
11. 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: 22.03.2021).

### NEURAL NETWORK SYSTEM FOR PREDICTING THE RESULTS OF THE BIATLON WORLD CUP

**Rosihina Evgeniya Mikhailovna**

Perm State University  
Str. Bukireva, 15, Perm, Russia, 614068,  
[zheniarosihina@gmail.com](mailto:zheniarosihina@gmail.com)

The article describes the development of a neural network system for predicting the results of a sportsman in various races of the Biathlon World Cup. The system allows people to determine the approximate place that a biathlete will take in the competition, taking into account his psychological and physical indicators.

**Keywords:** biathlon, artificial intelligence, neural network technologies, prediction, shooting percentages, rate of fire, speed, sport.

## Секция: Развитие технологий искусственного интеллекта

УДК 004.8

### ПРОБЛЕМЫ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ В ЗАДАЧАХ КОМПЬЮТЕРНОГО ЗРЕНИЯ И ПУТИ РАЗВИТИЯ ОБЪЯСНИМОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

*Гладкий Сергей Леонидович*

ООО «Випакс-Разработчик», 614000, Россия, г. Пермь, ш. Космонавтов, 111,  
lrndlrnd@mail.ru

В работе приведен обзор теоретических проблем нейронных сетей, возникающих в задачах компьютерного зрения. Рассмотрены проблемы обобщающей способности сверточных нейронных сетей, проблема катастрофической забывчивости и проблема интерпретации результатов работы глубоких нейронных сетей. Для каждой из проблем изложены гипотезы о некоторых возможных причинах их возникновения и предложены методы и направления развития нейросетевых моделей с целью устранения данных проблем. Хотя рассмотренные проблемы носят чисто теоретический характер, их решение может иметь большое практическое значение для дальнейшего развития искусственного интеллекта.

**Ключевые слова:** сверточная нейронная сеть, нейронная сеть на основе знаний, глубокое обучение, компьютерное зрение, распознавание изображений, переносимое обучение, обобщающая способность, катастрофическая забывчивость, объяснимый искусственный интеллект.

**Введение.** Благодаря революции искусственного интеллекта (ИИ) в начале XXI-го века, связанной с развитием сверточных нейронных сетей (СНС) и глубокого обучения, интеллектуальные системы превзошли человеческие возможности во многих задачах компьютерного зрения [1-6]. Среди наиболее значимых достижений ИИ в области анализа изображений следует отметить распознавание лиц по фотографиям и сегментацию медицинских снимков. Однако, несмотря на несомненные успехи нейронных сетей в практическом применении, остаются важные нерешенные теоретические вопросы, связанные с пониманием принципов работы и интерпретацией результатов нейросетевых моделей.

В работе рассматриваются три из наиболее важных теоретических проблем нейросетевого моделирования: проблема обобщающей способности СНС, проблема катастрофической забывчивости и проблема объяснимости результатов глубоких нейронных сетей.

**Проблема обобщающей способности.** Обобщающей способностью нейронной сети называется ее способность давать правильный результат для входных данных, которые не были использованы в процессе обучения [4]. Точное определение числового значения обобщающей способности конкретной нейронной сети не представляется возможным, поскольку полная выборка множества входных данных недоступна в практических приложениях.

На практике, обычно используется следующий подход. Полная выборка доступных исходных данных делится на две части – обучающую и валидационную. При обучении используется только обучающая, а для определения обоб-

щающей способности вычисляется точность работы нейронной сети на значениях валидационного множества. В некоторых случаях выделяется так же третья выборка – тестирующая.

Такой подход не позволяет решить проблему обобщения. В реальных задачах тренировочная и валидационная выборки по сути являются частями одного подмножества данных и, вероятно, будут иметь схожую функцию распределения вероятности образцов в многомерном пространстве входных данных. Таким образом, валидация будет происходить на точках пространства, близких к тренировочным данным.

Основной же проблемой обобщения является то, как нейронная сеть будет работать на точках пространства исходных данных, **достаточно далеко удаленных** от точек тренировочной выборки (но лежащих внутри минимальной в некотором смысле оболочки, натянутой на точки, входящие в тренировочную выборку).

Одним из направлений развития, может быть, создание нейронных сетей на основе знаний. В [7, 8] демонстрируется создание нейронных сетей, основанных на знаниях о решаемой задаче – распознавании печатных символов. Показано, что заложенные в нейросеть знания позволяют повысить обобщающую способность модели.

В работе [9] показано снижение обобщающей способности нейронных сетей в следствии цветовой зависимости. Данную проблему можно решить, удалив из исходных данных информацию о цветах, то есть, заложив в модель знания о том, что классы объектов не определяются цветовыми характеристиками.

Следует отметить, что нейросетевые модели на основе знаний могут быть построены для ограниченного класса простых задач компьютерного зрения. Создание моделей для практических задач требует разработки принципиально новых подходов к проектированию и обучению глубоких нейронных сетей.

**Проблема катастрофической забывчивости.** Катастрофическая забывчивость нейронных сетей – это феномен, который проявляется в значительном снижении точности работы нейронной сети при обучении ее на новых данных, отличных от предыдущих [10]. Эта особенность приводит к невозможности дообучения нейронных сетей, то есть при появлении новых данных необходимо использовать для обучения полную выборку.

Для задач компьютерного зрения выдвинута следующая гипотеза: катастрофическая забывчивость СНС связана с наличием многослойного персептрона в головной части модели.

Поясним это на примере классификатора изображений. Наиболее используемой архитектурой классификатора является модель, состоящая из экстрактора признаков, за которым следует многослойный персептрон. Исследования показывают, что современные экстракторы признаков обучаются выделению значимых высокоуровневых признаков, о чем свидетельствует успех применения переносимого обучения в задачах распознавания изображений. Гипотеза состоит в том, что часть персептрона, ответственная за принятие конечного решения, какому классу принадлежит объект на изображении, обучается по принципу **запоминания множества сочетаний** высокоуровневых признаков для **конкретных конфигураций объектов** в множестве обучающих данных. Именно здесь, согласно выдвигаемой гипотезе, теряется обобщение данных.

Одним из возможных способов преодоления потери обобщающей способности может быть замена перцептрона на нейросети Колмогорова-Арнольда (Kolmogorov-ArnoldNetwork, KAN) [10]. Основными отличительными особенностями нейросетей Колмогорова-Арнольда является наличие обучаемых активационных функций и их расположение на ребрах графа. Как показано в [10] на задачах аппроксимации многомерных функций, KAN не подвержены феномену катастрофической забывчивости.

**Проблема объяснения результатов нейронных сетей.** Точность работы современных нейронных сетей в некоторых задачах компьютерного зрения превосходит человеческие возможности. Тем не менее, когда нейронная сеть ошибается, то объяснить ошибку в большинстве практических случаев не представляется возможным. Лучшие нейронные сети состоят из сотен и даже тысяч слоев и выделяют тысячи признаков на различных уровнях. Поэтому, выяснение вывода нейронной сети для ошибочного экземпляра данных является крайне дорогостоящей задачей, поскольку требует анализа нейронной сети на каждом уровне

Одним из подходов к решению данной проблемы может быть разработка интерпретируемых моделей компьютерного зрения, например, как в работе [11]. Построение модели с заранее выверенной архитектурой, которая определяет ее поведение, позволяет более просто и надежно проследить логику вывода нейронной сети при ошибке, тем самым обеспечивая интерпретируемость ее результатов.

Вторым методом может быть построение нейронных сетей на основе знаний [7, 8]. При контролируемом обучении нейронных сетей, в них закладываются знания, путем обучения заранее известным признакам, которые являются значимыми для решения данной задачи. Таким образом нейронная сеть так же является интерпретируемой, поскольку известно, какие признаки она выделяет.

Третий подход может быть основан на применении нейронных сетей Колмогорова-Арнольда. По утверждению авторов, данные нейросети позволяют строить интерпретируемые модели нейронных сетей для задач аппроксимации функций и решения дифференциальных уравнений [10]. Для построения интерпретируемых KAN в задачах компьютерного зрения необходимо разработать специальные архитектуры нейронных сетей.

Отметим, что все три подхода имеют общую черту – в нейросети закладываются априорные знания разработчика о решаемой задаче. В первом случае знания заложены на этапе проектирования архитектуры нейронной сети. Во втором – на этапе обучения нейронной сети признакам, значимым для решения данной задачи. В третьем случае, архитектура нейронной сети основана на знании о возможности представления функции нескольких переменных через множество функций одной переменной по теореме Колмогорова-Арнольда.

### **Заключение.**

В работе рассмотрены три теоретические проблемы нейросетевых моделей, применяемых в задачах компьютерного зрения: проблема обобщающей способности, проблема катастрофической забывчивости и проблема объяснимости результатов работы глубоких нейронных сетей.

Выдвинуты гипотезы о возможных причинах данных проблем. Все гипотезы полагают, что проблемы возникают из-за неоптимальной архитектуры ис-

пользуемых в настоящее время нейронных сетей. Базовые архитектуры СНС, используемые в компьютерном зрении, имеют целью обучение (по сути – запоминание) большого числа вариантов распознаваемых изображений, а не обобщение знаний. Для создания интерпретируемых нейронных сетей с лучшей обобщающей способностью, без катастрофической забывчивости, необходима разработка новых архитектур, основанных на знаниях о решаемой задаче.

Несмотря на теоретический характер данных проблем, их решение может привести в будущем к значительному прогрессу и в практических целях, поскольку более глубокое понимание принципов работы нейронных сетей может дать импульс для развития новых подходов к проектированию более производительных и точных архитектур нейросетевых моделей.

### Библиографический список

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. – 2-е изд., испр. – М.: ДМК Пресс, 2018. – 652 с.
2. Николенко С., Кадуринов А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – СПб.: Питер, 2018. – 480 с.
3. Chollet F. Deep Learning with Python. – NY.: Manning Publications Co., 2018. – 386 p.
4. Rosebrock A. Deep Learning for Computer Vision with Python. Starter Bundle. – pyimagesearch.com, 2017. – 332 p.
5. Rosebrock A. Deep Learning for Computer Vision with Python. Practitioner Bundle. – pyimagesearch.com, 2017. – 210 p.
6. Rosebrock A. Deep Learning for Computer Vision with Python. ImageNet Bundle. – pyimagesearch.com, 2017. – 323 p.
7. Гладкий С.Л. Переносимое обучение на основе знаний в компьютерном зрении. // Сборник статей по материалам Международной конференции «Интеллектуальные системы в науке и технике» (г. Пермь, 12-18 октября 2020 г) / под редакцией Л. Н. Ясницкого; Пермский государственный национальный исследовательский университет. – Пермь, 2020. С. 76-86.
8. Гладкий С.Л. Сверточная нейронная сеть на основе знаний для распознавания символов. // Сборник статей по материалам Международной конференции «Интеллектуальные системы в науке и технике» (г. Пермь, 21-22 октября 2020 г) / под редакцией Л. Н. Ясницкого; Пермский государственный национальный исследовательский университет. – Пермь, 2021. С. 412-422.
9. Гладкий, С. Л. Исследование цветовой зависимости сверточных нейронных сетей в задачах компьютерного зрения / С. Л. Гладкий, С. Д. Халявин // Прикладная математика и вопросы управления. – 2024. – № 1. – С. 111–122. – DOI 10.15593/2499-9873/2024.1.07 [в печати]
10. KAN: Kolmogorov-Arnold Networks / Z. Liu, Y. Wang, S. Vaidya, F. Ruehle, J. Halverson, M. Soljačić, T.Y. Hou, M. Tegmark / 2024. – URL: <https://arxiv.org/abs/2404.19756> (дата обращения: 21.08.2024)
11. Transparency by Design: Closing the Gap Between Performance and Interpretability in Visual Reasoning/ D. Mascharka, P. Tran, R. Soklaski, A. Majumdar / 2018. – URL: <https://arxiv.org/pdf/1803.05268> (дата обращения: 21.08.2024)

### PROBLEMS OF NEURAL NETWORK MODELS IN COMPUTER VISION AND DIRECTIONS TO INTERPRETABLE ARTIFICIAL INTELLIGENCE

*Sergey L. Gladkiy*

LLC «VIPAKS-Developer», Kosmonavtov av., 111, Perm, Russia, 614000,  
lrndlrnd@mail.ru

The work concerns three important theoretical problems of neural networks, arising in the computer vision: problem of generalization, catastrophic forgetting problem, and the problem of interpretability of deep neural network results. Some hypothesis of possible reasons of the problems suggested. The directions of developing neural network models proposed to overcome partially the problems.

Despite of the theoretical type of the considered problems, their solution can provide strong impact on the future progress in the artificial intelligence.

**Keywords:** convolutional neural network, knowledge based neural network, deep learning, computer vision, image recognition, transfer learning, generalization, catastrophic forgetting, interpretable artificial intelligence.

УДК 004.032.26

## ПОИСК ВЫБРОСОВ В СТАТИЧЕСКИХ ДАННЫХ ОТНОСИТЕЛЬНО ЗАВИСИМОГО ПРИЗНАКА

*Бочкарев Владислав Антонович*

Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
pikova98@gmail.com

В статье представлено описание алгоритма для поиска выбросов среди статических данных относительно зависимого признака. Предложенный алгоритм позволяет эффективно находить аномалии среди данных как при малых, так и для больших датасетов.

**Ключевые слова:** фильтрация данных, поиск аномалий.

**Введение.** Прогнозирование выбросов в статических данных является важной задачей машинного обучения и анализа данных. Аномалии в данных могут возникать по разным причинам: ошибки измерений, аномальные события или даже намеренные искажения данных. В современных условиях, когда объемы собираемых данных стремительно растут, возрастает и актуальность методов их обработки для повышения качества моделей.

В данной работе рассмотрен метод поиска и устранения выбросов на основе итерационной фильтрации данных с использованием специальной модели, которая устойчива к аномалиям, как логическое продолжение и улучшение метода поиска выбросов предложенного в статье Ф.М. Черепанова и Л.Н. Ясницкого [1]. Основная цель – проектирование и тестирование алгоритма, способного автоматически находить выбросы, устраняя их влияние на качество модели. Это позволит улучшить процесс обучения и повысить точность предсказаний в задачах классификации и регрессии.

**Постановка задачи.** Требуется создать алгоритм итерационной фильтрации данных относительно зависимого признака, абстрактно можно описать схемой, изображенной на рис. 1.

Подразумевается, что при обучении специальной модели на каком-либо признаке, модель будет способна воспроизвести внутренний закон распределения данных. Тогда при исследовании различия предсказанного признака (по независимой части) от истинного значения зависимого признака, мы должны увидеть большие отклонения для выбросов. Это произойдет по естественной причине отклонения значений исследуемого примера от закона распределения, которому была обучена модель. Таким образом, если мы будем итерационно

находить примеры с большими отклонениями, удалять их и переучивать модель, наша модель и данные будут сходиться к истинному распределению данных.

**Проектирование и тестирование реализации.** Самая главная задача при реализации данного подхода – выбор базовой модели. Нейросетевые модели слишком медленные для данной задачи, потому было решено использовать модели градиентного бустинга.

Тестирование алгоритма проведено на нескольких наборах данных с различными характеристиками, включая задачи классификации и регрессии. Результаты показали улучшение качества предсказаний модели после удаления выбросов, что подтверждается как численными метриками (такими как precision, recall и r2), так и визуализацией данных.

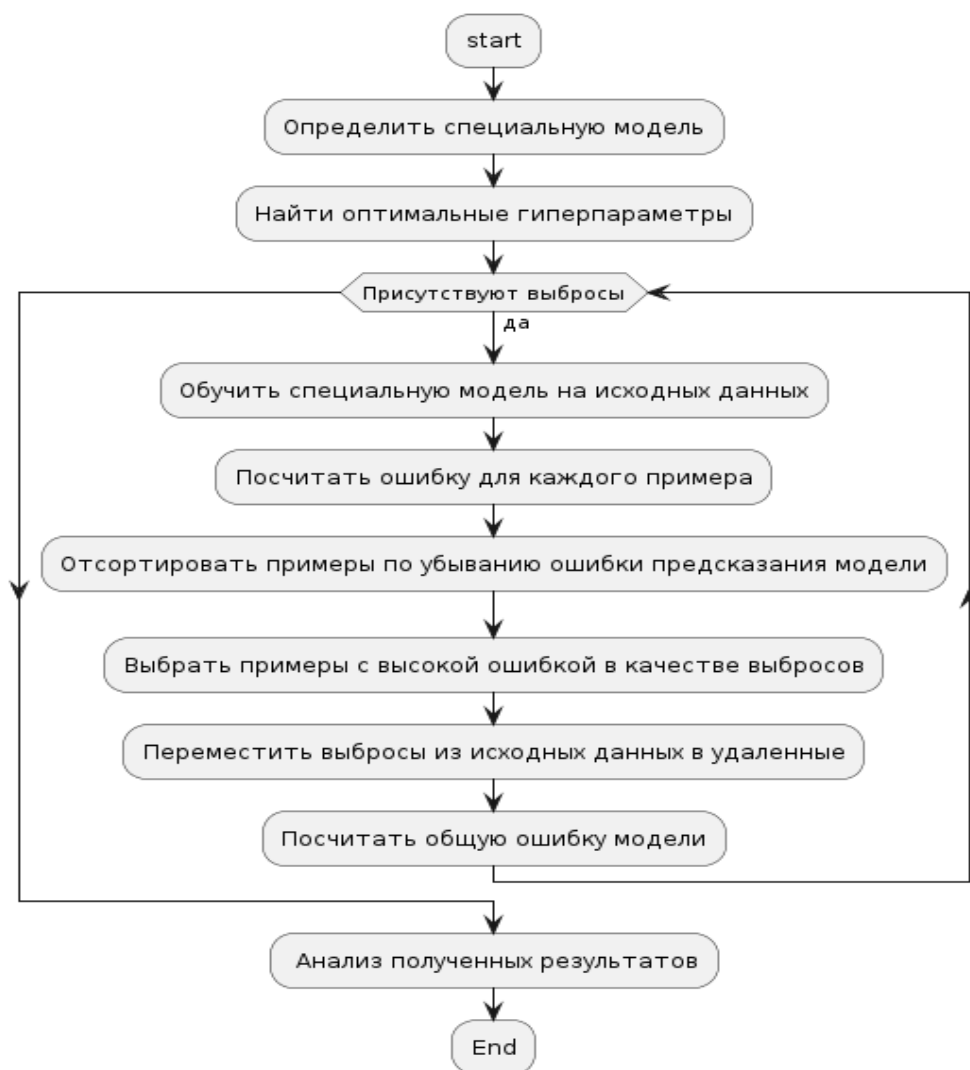


Рис. 1. Абстрактная схема работы алгоритма

**Классификация отказа сердца.** После загрузки датасета [2] и обучении модели имеем следующий результат оценки качества классификатора с кросс-валидации при  $cv=10$  и 3 повторениями:



class	precision	recall	f1-score	support
1	0.84	0.94	0.89	609
0	0.84	0.62	0.71	288

Для того чтоб лучше показать эффективность алгоритма, было удалено 30% данных, которых алгоритм посчитает выбросами.

Но в процессе выполнения алгоритма, было встречено увеличение значения ошибки от метрики модели, и в итоге было удалено 19% данных

Та же метрика после удаление выбросов:

class	precision	recall	f1-score	support
1	1.00	1.00	1.00	537
0	1.00	1.00	1.00	189

Как видно, по результатам многократной кросс-валидации, модель успешно всегда разделяет классы, и мы имеем идеальную точность.

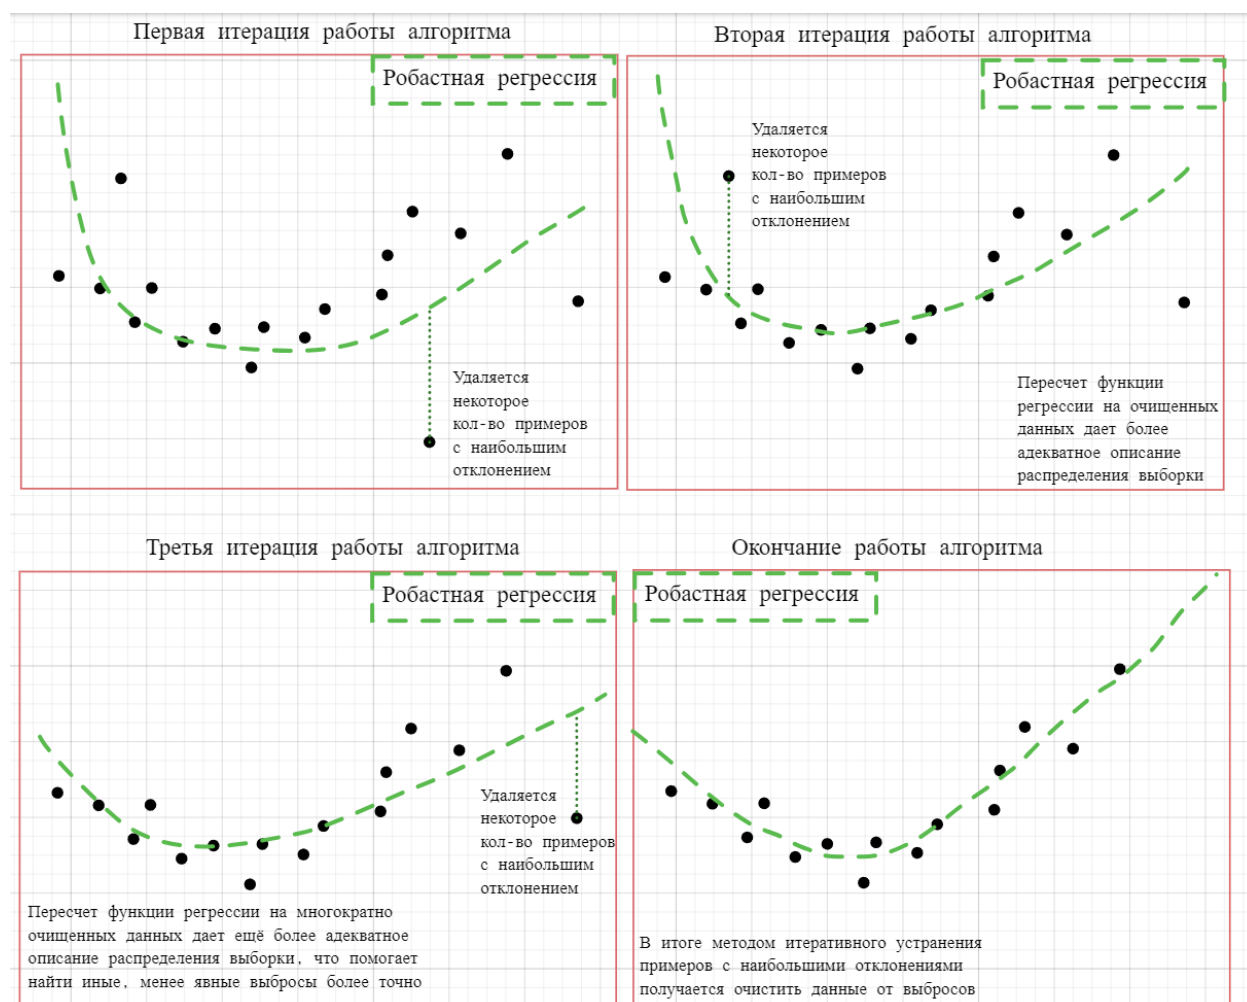


Рис. 2. Абстрактная схема итерации алгоритма

Используя отображение исходных многомерных данных в 2 координаты используя PCA, и отображая каждый класс в свой цвет, получаем визуализацию ниже.

Как видно, алгоритм не только по результатам метрики, но и визуально очень вразумительно удалил выбросы. Два “рукава” разных классов стали куда чище и четче.

**Регрессия возобновляемой энергетики.** После загрузки датасета [3], делается регрессия по параметру произведенной энергии. После загрузки и кросс-валидации с  $cv=5$  и 3 повторениями,  $r^2$  метрика модели на исходных данных равна;  
 $r^2 = 0.922$

Выполнен поиск выбросов с параметрами  $\gamma = 0.9$ ,  $cv=5$ ,  $repeats = 3$ ,  $iterations = 5$ .

После удаления 10% выбросов, так же  $r^2$  метрика модели на очищенных данных равна:  
 $r^2 = 0.989$




Рис. 3. Визуализация выбросов датасета классификации отказа сердца

Делая визуализацию данных, используя PCA с 2 компонентами, получаем следующие графики.

Как видно, и по  $r^2$  метрике, и по визуальной оценке качества данных, алгоритм успешно удалил выбросы и сделал данные чище. Среди «Линий» данных, стало гораздо меньше шума, распределение стало равномернее, более предсказуемо.




Рис. 4. Визуализация очистки выбросов датасета регрессии возобновляемой энергии

**Классификация семян. После загрузки датасета [4] и обучении модели имеем следующий результат оценки качества классификатора с кросс-валидации при  $cv=10$  и 3 повторениями**

class	precision	recall	f1-score	support
0	0.91	0.89	0.90	198
1	0.97	0.96	0.97	204
2	0.93	0.95	0.94	195

Выполнен поиск выбросов с параметрами **gamma = 0.9, cv=5, repeats = 5, iterations = 5**

Та же метрика после удаления 5% выбросов

class	precision	recall	f1-score	support
0	0.96	0.90	0.93	189
1	1.00	0.99	0.99	201
2	0.91	0.98	0.94	192

Как видно, практически все показатели стали лучше.

Делая отображение данных датасета в 3 измерения через Kernel PCA, и используя цвет как обозначение класса можно сделать плот исходных и очищенных данных:

На рисунках ниже представлены результаты работы алгоритма.

Можно заметить, как даже визуально были удалены примеры, которые по своему классу явно не находятся в неправильном положении, особенно на границе красного и синего кластера.




Рис. 5. Визуализация выбросов датасета классификации семян

**Заключение.** В результате исследования построен и протестирован алгоритм поиска и устранения выбросов из статических данных.

## Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статической информации : <https://cyberleninka.ru/article/n/neyrosetevoy-filtr-dlya-isklyucheniya-vybrosov-v-staticheskoy-informatsii>
2. Датасет отказа сердца: <https://www.kaggle.com/datasets/andrewmvd/heart-failure-clinical-data>
3. Датасет возобновляемой энергии: <https://www.kaggle.com/datasets/pythonafroz/renewable-power-generation-and-weather-conditions/>
4. Датасет классификации семян: <https://www.kaggle.com/code/jmcaro/machine-learning-classifiers-wheat-seeds/input>

## OUTLIERS SEARCH IN STATIC DATA RELATION TO A DEPENDENT FEATURE

***Bochkarev V. Antonovich***

Perm State National Research University,  
Str. Bukireva, 15, Perm, Russia, 614068  
pikova98@gmail.com

The article presents a description of an algorithm for detecting outliers in static data relative to a dependent feature. The proposed algorithm allows for efficiently identifying anomalies in datasets, both small and large.

**Keywords:** data filtering, anomaly detection.

УДК 004.032.26

## О НЕКОТОРЫХ ПРОБЛЕМАХ ФОРМИРОВАНИЯ ОБУЧАЮЩИХ НАБОРОВ ДАННЫХ В ИСКУССТВЕННОМ ИНТЕЛЛЕКТЕ

***Лосев Александр Георгиевич***

Волгоградский государственный университет,  
400062, Россия, г. Волгоград, пр. Университетский, 100  
alexander.losev@volsu.ru

Статья посвящена обсуждению некоторых проблем, возникающих при разработке новых методов формирования обучающих наборов данных в медицине. Предлагаются подходы, основанные на использовании технологий искусственного интеллекта, а также компьютерного и суррогатного моделирования.

**Ключевые слова:** интеллектуальный анализ данных, компьютерное моделирование, медицинская диагностика, объяснимый искусственный интеллект.

**Введение.** Одной из ключевых проблем искусственного интеллекта является разработка методов правильного формирования обучающего набора данных, используемого в решении различных задач машинного обучения. Особенно остро данная проблема стоит при работе с малыми данными. В настоящее время, по различным причинам, большее внимание уделяется разработке методов обработки больших данных. Иногда, по не очень понятным автору причинам, даже отождествляют искусственный интеллект с большими данными. При этом в ряде задач, например в задачах медицинской диагностики, зачастую приходится иметь дело именно с относительно небольшими наборами данных. И алгоритмы, разработанные для анализа больших данных, в большинстве случаев не очень подходят для анализа малых данных. Впрочем, разработка методов правильного формирования обучающей выборки актуальна и в других случаях. Более того, подавляющее большинство специалистов признает, что правильное формирование обучающей выборки зачастую имеет ключевое значение

в решении задач интеллектуального анализа данных. При этом теоретическая база данной задачи находится на начальной стадии разработки.

**Постановка задачи и проблемы формирование DataSet.** Известно, что натурные данные, полученные посредством измерений, могут обладать следующими недостатками:

1. Наличие ошибок результатов измерений. Это могут быть как пропуски данных, так и некорректные измерения, связанные с человеческим фактором, неисправностью техники или иными причинами;

2. Наличие ошибок в метках. Особую сложность данной задаче придает тот факт, что ошибки могут быть связаны не только с погрешностью измерений, но и с релевантностью данных принятым моделям. Данная проблема в последние годы обозначилась практически во всех сферах применения методов искусственного интеллекта, но особенно она характерна для медицинских данных. По мнению некоторых специалистов, в медицинских картах пациентов может содержаться до 30 процентов неточных диагнозов, что порождает неверные метки, которые в дальнейшем используются в обучающих выборках алгоритмов классификации.

С другой стороны, также доподлинно неизвестно насколько адекватно модель отражает действительность. Отмечается [1], что в принятых моделях зачастую содержатся некорректные данные, далекие от реальности, причем связано это не с методами измерений, а с пониманием проблемы. Получается, что данные отражают не объективную сущность, а восприятие этой сущности тех, кто формировал эти данные, что далеко не всегда верно.

Методы машинного обучения способны извлекать знания из статистической информации. Но, если в представленных для обучения датасетах знаний нет, то методы машинного обучения бессильны. В этой связи возникает задача разработки методов, позволяющих все-таки выделить ту истину, которая содержится в данных и нивелировать ошибки, а также принципиально новых методов аугментации данных и формирования обучающего набора данных в интеллектуальном анализе данных.

3. Наличие персональных данных. Последнее может породить трудности с распространением набора данных и валидацией полученных результатов.

4. Малый набор данных. В зависимости от предметной области сложность составления набора данных варьируется. Так, например, в медицине гораздо легче составить большой набор данных на основе обследований здоровых или пациентов с наличием распространенных заболеваний, нежели на редко встречаемых.

5. Несбалансированность данных. Как правило, при решении различных задач модели машинного обучения должны быть непредвзятыми и в равной степени определять как объекты мажоритарного класса, так и миноритарного. В тоже время важна и равнозначность оценивания месторасположения объектов в признаковом пространстве.

Обозначенные проблемы в известной степени возможно решить на основе синтезирования набора данных различными методами. Например, статистическими методами в какой-то мере можно пытаться решить проблемы №3, №4

и №5, а проблемы №1 и №2 решить до степени распространенности соответствующих ошибок в обучающем наборе данных.

Весьма перспективным выглядит подход, заключающийся в создании компьютерных моделей с достаточно высокой степенью описывающих природу исследуемых объектов (см., например, [2]). Построенный за счет подобных моделей набор данных позволяет в большей мере решить обозначенных проблем, т. к. полученные модели не будут содержать ошибки как в метках, так и в измерениях. Более того построенные модели позволяют выявлять новую качественную информацию об изучаемом объекте за счет большего количества информации.

Однако синтез набора данных на основе компьютерных моделей порождает свои проблемы.

1. Во-первых, в данной ситуации предъявляются крайне высокие требования к адекватности модели. Для построения качественных моделей требуются: понимание структуры объекта и процессов, происходящих в исследуемом объекте, качественные и эффективные математические и численные модели;

2. Во-вторых, из-за сложной структуры возникают проблемы в управляемом получении набора данных, обладающего заранее заданными свойствами;

3. Также из-за сложной структуры требуется большое количество времени (по сравнению со статистическими методами) для генерации новых объектов.

Последнюю проблему позволяет решить суррогатное моделирование. Данный подход по небольшому набору компьютерных моделей способен построить собственную упрощенную модель. На основе последней становится возможным быстрое конструирование и подбор объектов, необходимых для решения поставленной задачи. Однако, при этом, проблемы адекватности модели остаются актуальными.

Отдельно отметим круг задач, связанных с разработкой методов формирования полного и достоверного набора данных на основе натуральных. Перечислим задачи, относящиеся в данной группе:

1. Разработка методов фильтрации набора данных. Исходный набор данных может содержать как достоверную информацию, так и различного рода ошибки. Следующие задачи направлены на их нахождение и корректировку:

- А) Определение недостоверных данных. Данная задача связана с ошибками измерений, в результате которых объект содержит некорректные описания. В зависимости от типа ошибок возможна как их корректировка, так и удаление объекта из обучающего набора данных.

- В) Корректировка меток. Задача связана с нехарактерностью описания объекта присвоенному ему классу. Данная нехарактерность может быть связана, как с ошибочным присвоением метки, так и с самой аномальностью объекта (в данном случае предполагается, что метка присвоена верно). В таких случаях считается, что искусственное изменение меток в обучающем наборе данных улучшит его качество при дальнейшем синтезировании компьютерных моделей.

С) Доопределение меток. Вполне возможна ситуация, когда, помимо полностью размеченного набора данных, также имеется полуразмеченный набор данных. В таком наборе у объектов может стоять множество возможных меток. Данные объекты возможно использовать для дополнения обучающего набора, а именно множества объектов минорных классов.

2. Построение информативных областей признакового пространства. Полученные информативные области позволяют выделить, во-первых, области характерных значения для объектов различных классов, а также выявить области, в которых наблюдается нехватка объектов. Последние области предполагается дополнять объектами, полученных посредством компьютерного и суррогатного моделирования.

3. Построение характеристик синтетического набора данных, которым будет дополняться полученный обучающий набор.

Также отметим важнейший аспект разработки моделей искусственного интеллекта в задачах медицинской диагностики. Автору основным направлением в решении данных задач видятся алгоритмы объяснимого искусственного интеллекта. Причем весьма перспективным выглядит подход на основе разработки математических моделей диагностического состояния пациента, каждый элемент которых понятен врачу-диагносту и легко им интерпретируется (см., например, [3]).

### **Библиографический список**

1. Gorban A. N., Makarov V. A., Tyukin I. Y. Symphony of high-dimensional brain: Reply to comments on “The unreasonable effectiveness of small neural ensembles in high-dimensional brain” / *Physics of Life Reviews*, 2019, 29, 115
2. 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. 1084, с. 447-460
3. Levshinskii V, Galazis C, Losev A, Zamechnik T, Kharybina T, Vesnin S, Goryanin I. Using AI and passive medical radiometry for diagnostics (MWR) of venous diseases. *Computer Methods and Programs Biomed.* 2022 Mar;215:106611.

## **SOME PROBLEMS OF FORMING TRAINING DATASETS IN ARTIFICIAL INTELLIGENCE**

***Alexander G. Losev***

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

The article is devoted to the discussion of some problems that arise in the development of new methods for the formation of training data sets in medicine. Approaches based on the use of artificial intelligence technologies, as well as computer and surrogate modeling are proposed.

**Keywords:** data mining, computer modeling, medical diagnostics, explainable artificial intelligence

## ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ В СИСТЕМЕ ОБЪЯСНИМОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

*Попов Илларион Евгеньевич*

Волгоградский государственный университет,  
4000062, Россия, г. Волгоград, пр. Университетский, 100  
popov.larion@volsu.ru

В статье предложен подход по построению системы объяснимого искусственного интеллекта в задачах классификации. Система состоит из двух модулей: ансамбля алгоритмов машинного обучения, поддающихся интерпретации и модели нейронной сети. На основе второй достигается высокоточная классификация и выбирается наиболее адекватное обоснование, сформированное ансамблем алгоритмов.

**Ключевые слова:** объяснимый искусственный интеллект, нейронные сети, лес решений.

**Введение.** На сегодняшний день объяснимый искусственный интеллект находится на ранней стадии развития, а большинство моделей машинного обучения, по сути своей, являются черными ящиками, не поддающимися интерпретации. В тоже время актуальной является задача создания экспертных систем, способных, помимо предоставления своего решения, еще и к его объяснению. Подобные системы повышают доверие специалистов к методам искусственного интеллекта, а также предоставляют полезную информацию о причинах того или иного решения.

Для создания систем объяснимого искусственного интеллекта можно использовать как интерпретируемые модели машинного обучения, так и сложные модели, объяснимость которых достигается с помощью специальных методов, таких как LIME, SHAP или визуализации активаций [1, 5]. Недостатком описанных специальных методов является то, что они работают с моделями как с черным ящиком и не объясняют внутреннюю логику вывода того или иного решения. Интерпретируемые модели, в свою очередь, способны сформировать более полное обоснование предлагаемого решения. При этом чем сложнее и точнее модель машинного обучения, тем сложнее она интерпретируется. Так, нейронная сеть считается черным ящиком в общем случае, а дерево решений или наивный байесовский классификатор – интерпретируемыми [3, 6].

Чтобы предлагаемое решение было одновременно высокоточным и интерпретируемым, в работе предлагается синтез моделей машинного обучения.

**Модель.** Одними из главных критериев оценивания системы объяснимого искусственного интеллекта являются точность объяснения, в частности,



предсказания класса объекта, а также ее глобальная интерпретируемость, т. е. объяснение должно покрывать общую логику работы модели [2, 4].

Ключевым элементом предлагаемой системы является ансамбль интерпретируемых алгоритмов классификации. Это может быть случайный лес, состоящий из деревьев решений, ансамбль линейных регрессий или наивных байесовских классификаторов. Особенность ансамбля моделей машинного обучения заключается в разнообразии предлагаемых решений. Данное разнообразие достигается за счет разных гиперпараметров, случайных подвыборок обучающего набора данных и наборов признаков для каждой модели. Таким образом помимо разнообразия в решениях, достигается и разнообразие в предлагаемых обоснованиях данных решений. Однако вывод обоснования по каждой модели является перегруженным и сложным для восприятия.

С целью выбора наиболее адекватного решения и, соответственно, обоснования предлагается использовать высокоточную модель машинного обучения, а именно, искусственную нейронную сеть. Так как каждая из моделей оценивает степень принадлежности объекта к тому или иному классу, появляется возможность сравнения данных степеней, а значит, и выявление наиболее близкого решения среди моделей ансамбля к решению нейронной сети. Таким образом алгоритм обоснования предлагаемого решения будет следующим:

1. Посчитать  $X$  – результат классификации объекта искусственной нейронной сетью. В случае бинарной классификации это будет значение от 0 до 1, где 0 – наиболее вероятно, что объект принадлежит классу 0, 1 – к классу 1.

2. Посчитать  $Y$  – результат классификации объекта ансамблем моделей машинного обучения.  $Y$  является массивом чисел, каждое из которых соответствует решению одной из моделей ансамбля.

3. Среди  $Y$  найти модель  $y$ , решение которой наиболее близко к  $X$ . Метод определения наиболее близкого решения может варьироваться. Это может быть как нахождение минимума модуля разности, так и нахождение минимума среди решений ансамбля той же группы, что и решение нейронной сети.

4. Построить обоснование по модели  $y$ .

На рис. 1 приведена архитектура предлагаемой системы и алгоритм генерации наиболее адекватного обоснования.

**Заключение.** В результате была предложена система объяснимого искусственного интеллекта, которая является одновременно и высокоточной за счет использования модели искусственных нейронных сетей, и информативной за счет использования ансамбля интерпретируемых моделей машинного обучения.

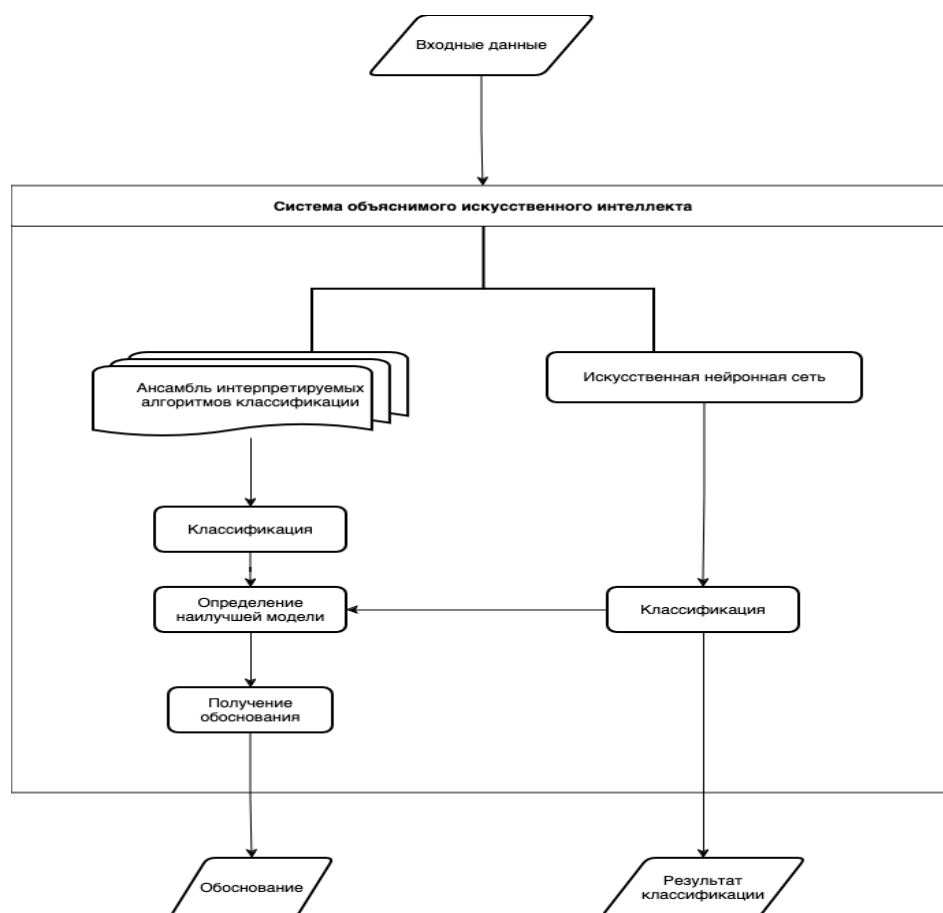


Рис. 1. Система объяснимого искусственного интеллекта

Данная система может применяться в различных сферах деятельности, где требуется высокий уровень доверия к искусственному интеллекту. Так, например, в медицинской диагностике для специалиста скорее важно не предлагаемое диагностическое решение, а то, на основании чего оно было получено.

## Библиографический список

1. Шевская, Н. В. Объяснимый искусственный интеллект и методы интерпретации результатов / Н. В. Шевская // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, №2(33).
2. Arrieta Alejandro Barredo, Díaz-Rodríguez Natalia, Del Ser Javier, Bennetot Adrien, Tabik Siham, Barbado Alberto, García Salvador, Gil-López Sergio, Molina Daniel, Benjamins Richard, et al. Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. Inf. Fusion, 58 (2020), pp. 82-115, 10.1016/j.inffus.2019.12.012.
3. Losev, A. G., Popov, I. E., Petrenko, A. Y., et al. Some Methods for Substantiating Diagnostic Decisions Made Using Machine Learning Algorithms // Biomedical Engineering. – 2022. – Vol. 55, No. 6. – P. 442-447. – DOI: 10.1007/s10527-022-10153-y.
4. Molnar, C. (2022). Interpretable Machine Learning: A Guide for Making Black Box Models Explainable (2nd ed.). URL: <https://christophm.github.io/interpretable-ml-book/> (дата обращения: 17.09.2024).
5. Ribeiro, M.T., Singh, S., Guestrin, C. "Why Should I Trust You?": Explaining the Predictions of Any Classifier // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – 2016. – P. 1135–1144. – DOI: 10.1145/2939672.2939778.
6. Rudin, C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. Nat Mach Intell 1, 206–215 (2019). <https://doi.org/10.1038/s42256-019-0048-x>.

# USING NEURAL NETWORKS IN EXPLAINABLE ARTIFICIAL INTELLIGENCE SYSTEM

*Illarion E. Popov*

Volgograd State University,  
400062, Russia, Volgograd, Prospect Universitetsky, 100  
popov.ilarion@volsu.ru

The article proposes an approach to constructing an explainable artificial intelligence system in a classification problem. The system consists of two modules: an ensemble of machine learning algorithms that can be interpreted and a neural network model. Based on the second, a highly accurate classification is achieved and the most adequate justification formed by the ensemble of algorithms is selected.

**Keywords:** explainable artificial intelligence, neural networks, decision forest.

УДК 004.8

## УСТРАНЕНИЕ ЦВЕТОВОЙ ЗАВИСИМОСТИ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ КОМПЬЮТЕРНОГО ЗРЕНИЯ

*Гладкий Сергей Леонидович*

ООО «Випакс-Разработчик», 614000, Россия, г. Пермь, ш. Космонавтов, 111,  
lrndlrnd@mail.ru

В работе рассматривается проблема зависимости сверточных нейронных сетей от цветовых параметров изображений. При решении задач распознавания изображений, в которых цвет не является значимым признаком, нейронные сети могут ошибочно обучиться распознавать объекты определенного класса на основе их цвета. Для решения данной проблемы предложена методика исключения цветовых составляющих изображения при сохранении полной информации о форме (геометрии) объектов. Методика заключается в преобразовании цветного изображения в градиентное. Разработаны вычислительные нейронные сети для получения градиентов цветного изображения. Проведено обучение и тестирование двух нейронных сетей на цветных и градиентных представлениях изображений. Показано отсутствие цветовой зависимости при обучении нейронных сетей на градиентных изображениях.

**Ключевые слова:** сверточная нейронная сеть, вычислительная нейронная сеть, глубокое обучение, компьютерное зрение, цветовая зависимость, распознавание изображений.

**Введение.** Использование сверточных нейронных сетей (СНС) является одним из основных факторов успеха глубокого обучения в приложениях компьютерного зрения [1, 2]. Самые эффективные СНС способны превзойти человека по точности решения во многих задачах компьютерного зрения, таких, как распознавание лиц и классификации изображений животных [3-6]. Несмотря на очевидные успехи применения СНС в задачах компьютерного зрения, остаются нерешенными многие проблемы, такие, как определение обобщающей способности нейронных сетей.

Для задач компьютерного зрения одним из главных факторов, влияющих на обобщающую способность, является качество (параметры изображений такие, как яркость, контрастность, цветовой баланс, четкость и др.) и состав (разнообразие форм и цветов объектов) изображений в обучающей выборке. Из всех исследований, касающихся влияния параметров изображений на обучение СНС, следует вывод, что они напрямую влияют на точность работы нейронных сетей [7]. Например, показано, что с помощью изменения цветовых параметров изображений (color attack) можно значительно снизить точность распознавания СНС [7-9]. В [10] показано наличие нейронов, реагирующих только на цвета в некотором узком диапазоне оттенков, а также нейронов, активирующихся только при наличии на изображении объектов определенного класса и цвета.

В работе [11] рассмотрена проблема цветовой зависимости при обучении СНС на задаче классификации объектов. Проблема возникает в множестве задач распознавания, когда цвет не является определяющим признаком класса объекта. При этом, если в обучающей выборке объекты разных классов имеют разные цвета, нейронная сеть обучается разделять объекты по цвету. Таким образом, возникает цветовая зависимость, которая приводит к снижению обобщающей способности. При тестировании такой нейронной сети на выборке изображений с измененными цветами объектов, СНС ошибочно определяет класс по тому цвету объекта, который был в обучающем множестве. Существенное снижение обобщающей способности нейронной сети, обусловленное проблемой цветовой зависимости явно продемонстрировано в [12] на примере решения задачи на визуальное мышление.

Проблема цветовой зависимости может быть решена деколоризацией изображений – преобразованием цветного изображения в значения интенсивности. Например, могут быть использованы оптимизированные алгоритмы, предложенные в [13, 14]. Однако, при любом алгоритме деколоризации происходит потеря информации о форме. Например, всегда будут присутствовать изолюминантные цвета, то есть различные цвета, которые данный алгоритм преобразует в одно значение яркости. Потеря информации очевидно приведет к снижению точности работы СНС.

В настоящей работе предложен метод устранения цветовой зависимости при обучении СНС в задачах компьютерного зрения. Метод заключается в преобразовании цветного изображения в форму градиентов. В отличие от обычной деколоризации, градиентное представление изображений полностью сохраняет информацию о форме (геометрии объектов) и исключает информацию о цветовых составляющих изображений.

**Постановка задачи и метод решения.** Проблема цветовой зависимости нейронных сетей (цвето-зависимого обучения) в задачах распознавания изображений может быть сформулирована следующим образом [11]: при обучении СНС на цветных изображениях, нейронные сети могут ошибочно обучиться распознавать объект по цветовым признакам, хотя данный цвет, по сути, значимым признаком данного объекта не является. Цветовая зависимость нейронной сети приводит к снижению ее точности на данных, с отличными от обучающей выборки цветовыми характеристиками объектов.

Для решения проблемы цветовой зависимости предлагается метод преобразования изображений в цвето-независимую форму. То есть, все изображения (как во время обучения, так и во время использования нейронной сети) должны быть преобразованы в такое представление, которое полностью удаляет цветовую информацию, и при этом полностью сохраняет информацию о форме (геометрии) объекта. А именно, предложено попиксельное представление в градиентной форме (формула 1).

$$RGB \rightarrow GRAD \quad (1)$$

где  $RGB \in R^3[0, 1]$  – цвет пикселя в формате RGB,  $GRAD \in R^2[-1, 1]$  – градиент цвета в данном пикселе изображения. Таким образом, трехканальное цветное изображение преобразуется в двухканальное, компонентами которого являются производные цвета в направлении осей изображения  $x$  и  $y$ .

Производная двух цветов  $C_1 = (R_1, G_1, B_1)$  и  $C_2 = (R_2, G_2, B_2)$  вычисляется по следующей формуле:

$$D(C_1, C_2) = \text{sign}(\|C_2\| - \|C_1\|) \cdot \|C_2 - C_1\| \quad (2)$$

где  $D \in R[-1, 1]$  – производная цвета,  $\|C\| \in R[0, 1]$  – векторная норма цвета,  $\text{sign}$  – ненулевая сигнатура значения (принимает строго значения -1 или 1).

Преобразование цветного изображения в градиентную форму (1) с вычислением производных по формуле (2) удовлетворяет двум условиям цвето-независимого представления. Во-первых, вся информация о цветовых составляющих удаляется из представления, поскольку величину производной определяет векторная норма, а не отдельные компоненты цвета. Во-вторых, полностью сохраняется информация о форме (геометрии), поскольку для любых отличных цветов производная будет иметь ненулевое значение.

Векторная норма цвета может быть вычислена по различным формулам в зависимости от целей и наличия вычислительных ресурсов. Предлагаются следующие формулы для вычисления векторной нормы цвета  $X = (X_1, X_2, X_3) \in R^3[-1, 1]$ :

$$\|X\| = \sqrt{(|X_1| + |X_2| + |X_3|)/3} \quad (3.1)$$

$$\|X\| = \tanh(|X_1| + |X_2| + |X_3|) \quad (3.2)$$

$$\|X\| = \ln((e - 1)(|X_1| + |X_2| + |X_3|)/3 + 1) \quad (3.3)$$

$$\|X\| = (|X_1| + |X_2| + |X_3|)/3 \quad (3.4)$$

$$\|X\| = (X_1^2 + X_2^2 + X_3^2)/3 \quad (3.5)$$

$$\|X\| = \sqrt{(X_1^2 + X_2^2 + X_3^2)/3} \quad (3.6)$$

$$\|X\| = (\exp((|X_1| + |X_2| + |X_3|)/3) - 1)/(e - 1) \quad (3.7)$$

$$\|X\| = \max(|X_1|, |X_2|, |X_3|) \quad (3.8)$$

Различные формулы вычисления векторной нормы (формулы 3.1 – 3.8) позволяют придать различную значимость разности цветов при малых и больших значениях компонент цвета, поскольку определяют нелинейную зависимость. Например, формулы 3.2 и 3.3 дают большее изменение значения нормы

в диапазоне малых значений компонент, в то время как формула 3.7 – в диапазоне высоких значений.

Для вычисления разности цветов в формуле (2) могут быть эффективно использованы численные операторы производной, применяемые в задачах компьютерного зрения. В работе предлагается использование операторов Собеля, Шарра и Прюитт.

Таким образом, задача нахождения градиентного представления изображения сводится к нахождению производных изображения по формуле (2) для двух осей  $x$  и  $y$  в каждом пикселе.

Для реализации преобразования в градиентную форму предлагается использование вычислительных нейронных сетей. Под вычислительной нейронной сетью понимается нейронная сеть, которая спроектирована для реализации определенной формулы или алгоритма без процесса какого-либо обучения, то есть все параметры сети задаются вручную на этапе проектирования. Использование вычислительных нейронных сетей вместо традиционных алгоритмов компьютерного зрения имеет несколько преимуществ. Во-первых, данные алгоритмы можно выполнять непосредственно на платформе запуска нейронных сетей на высокопроизводительных системах, оптимизированных для параллельного выполнения операций свертки и других операций, типичных для СНС. Во-вторых, в этом случае алгоритм преобразования можно непосредственно сделать частью нейронной сети, которая будет цвето-независимой для любого обучающего набора данных.

**Проектирование и тестирование вычислительной нейросети.** Вычислительная нейронная сеть преобразования цветного изображения в градиентное представление должна реализовывать формулу (2) для двух осей изображения  $x$  и  $y$ . Для эффективной реализации вычислительного алгоритма с помощью нейронных сетей формула (2) была разбита на две независимые части:

$$S(C_1, C_2) = \text{sign}(\|C_2\| - \|C_1\|) \quad (4.1)$$

$$G(C_1, C_2) = \|C_2 - C_1\| \quad (4.2)$$

Формула (4.1) вычисляет ненулевую сигнатуру разности норм цветов, формула (4.2) вычисляет норму разности цветов. Каждую из этих формул реализует свой блок нейросети. Блоки условно названы блоком сигнатуры и блоком градиента. Блоки вычисляют свои функции по двум осям изображения одновременно. Полная нейросеть названа нейросетью формы.

Для реализации данных блоков необходимы три составляющих: вычисление векторной нормы цвета по любой из формул (3.1-3.8); вычисление ненулевой сигнатуры; вычисление разности цветов. Эти компоненты алгоритма были реализованы также в виде отдельных блоков, что позволяет комбинировать различные сочетания алгоритмов вычисления нормы с различными операторами производной (Собеля, Шарра, Прюитт). Реализация выполнена в системе Keras на языке Python.

На рис. 1 изображена диаграмма нейронной сети формы №1, в которой в блоке градиентов реализована формула (3.2), а в блоке сигнатуры – формула (3.4); для вычисления разности цветов используется оператор Шарра.

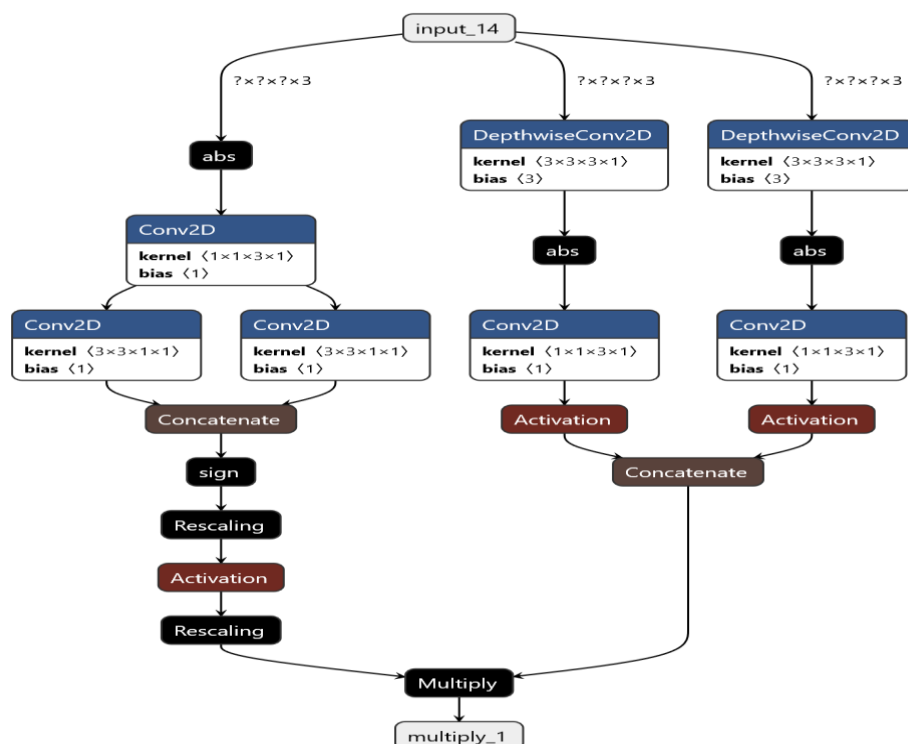


Рис. 1. Вычислительная нейронная сеть формы №1

На диаграмме видны два параллельных блока: блок сигнатуры слева и блок градиента справа. На выходе нейросети блоки объединяются с помощью поэлементной операции умножения для получения конечной формулы (2). Так же на диаграмме для каждого блока видно параллельное вычисление формулы для каждой оси изображения, которые в конце блока объединяются с помощью операции конкатенации по оси глубины.

На рис. 2 изображена диаграмма нейронной сети формы №2, которая отличается от сети №1 тем, что в блоке градиента используется формула нормы (3.7), а в блоке сигнатуры – формула (3.8).

Все реализованные блоки были протестированы на специальных изображениях. На рис. 3 представлено изображение, и вычисленное градиентное представление данного изображения (по оси x и y сверху вниз), вычисленное нейросетью формы №1.

**Эксперименты и анализ результатов.** Для подтверждения правильности гипотезы устранения цветовой зависимости спроектирован и проведен специальный эксперимент по распознаванию изображений. В качестве демонстрационной задачи выбрана задача классификации марок автомобилей. В данной задаче важна форма автомобиля, а не его цвет, таким образом задача позволяет выявить возможную цветовую зависимость при обучении.



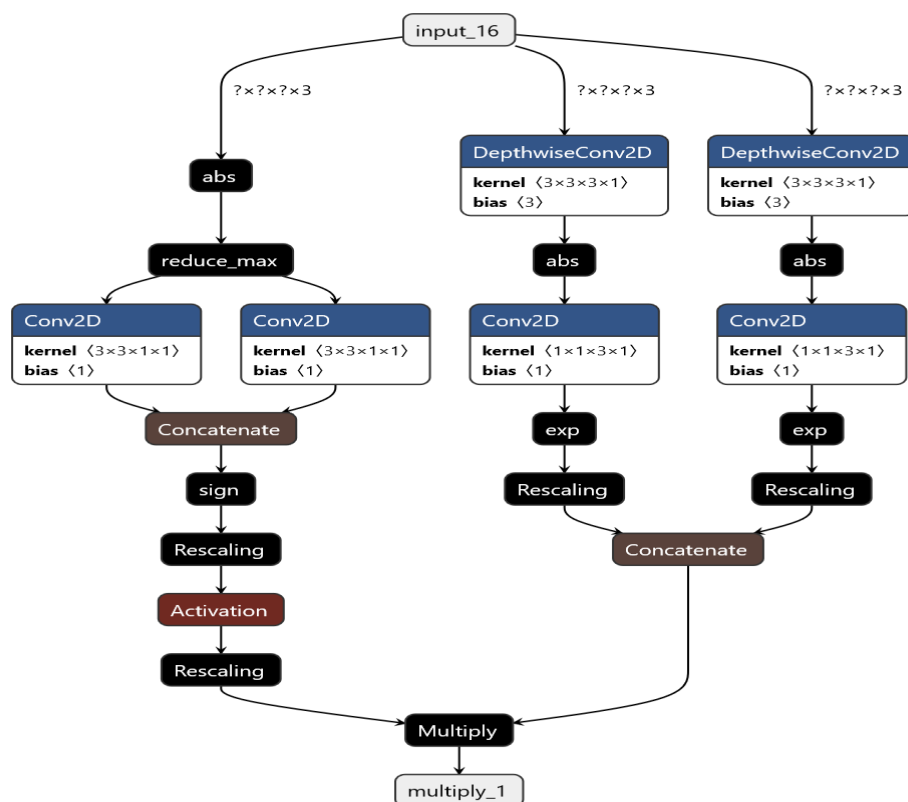


Рис. 2. Вычислительная нейронная сеть формы №2



Рис. 3. Тестовое изображение и его градиентное представление

В качестве базового набора изображений использован источник [15]. Для упрощения задачи с целью выявления возможной цветовой зависимости из данного набора сделана выборка для трех марок автомобилей Acura: ILX, MDX и NSX. Всего выборка содержит 181 изображение, приблизительно по 60 изображений на класс. Примеры изображений каждой из марок приведены на рис. 4. Поскольку исходных изображений недостаточно, чтобы получить приемлемую точность классификации при обучении, была выполнена аугментация изображений: поворот, приближение, удаление и отражение. Итоговый датасет составил 1086 изображений.

На данном наборе изображений обучены две СНС для классификации марок автомобилей на 3 класса. Обе нейросети имеют одну базовую архитектуру SqueezeNet с общим числом обучаемых параметров 724035. Первая нейросеть обучается на исходных цветных изображениях (далее данная нейросеть будет обозначена как базовая). В состав второй нейросети на входе включен блок формы (является необучаемым), который преобразует входное цветное изображение в градиентную форму (далее данная нейросеть будет обозначена как



нейросеть формы). Обе нейросети обучены на наборе аугментированных данных для получения максимальной точности на валидационной выборке без переобучения. Базовая нейросеть достигла точности валидации 92.6%, нейросеть формы – 89.8%.



Рис. 4. Примеры изображений выборки марок автомобилей Acura ILX, MDX и NSX

Далее, базовый набор из 181 изображения был подвергнут изменению цветовых характеристик. А именно, цвета автомобилей были изменены с помощью разработанной вычислительной нейросети. Синие автомобили были перекрашены в красный цвет, желтые и красные автомобили в синий цвет, остальные были оставлены без изменений. Из 181 изображения перекрашены были 64. Примеры изображений модифицированного набора данных приведены на рис. 5.



Рис. 5. Примеры изображений модифицированного набора данных

Обученные нейросети были протестированы на двух наборах данных – базовом наборе из 181 изображения и модифицированном, также состоящем из 181 образца. Результаты тестирования приведены в таблице.

Таблица

#### Результаты тестирования нейронных сетей

Нейронная сеть	Набор изображений	Точность, %
Базовая	Базовый	94.5
	Модифицированный	91.7
Нейросеть формы	Базовый	97.8
	Модифицированный	96.7

Из таблицы видно, что базовая модель продемонстрировала явную цветовую зависимость. Изменение цветов объектов в тестовом наборе привело к снижению точности обеих моделей. Базовая модель показала снижение точности на 2.8%, модель с блоком формы – на 1.1%. То есть, нейросеть формы про-

демонстрировала снижение точности в 2.5 раза меньшее (по количеству неверно классифицированных изображений), чем базовая модель. Таким образом, градиентное представление значительно снизило цветовую зависимость базовой модели. Незначительное снижение точности нейросети формы может быть связано с неидеальным изменением цветов объектов, которое могло привести к искажению формы объектов.

Кроме того, результаты в таблицы показывают, что градиентное представление может повысить точность работы базовой нейронной сети. Это может быть обусловлено тем, что градиентное представление предоставляет нейросети только необходимую информацию о форме, что приводит к формированию более полезных и значимых признаков нейронной сетью при обучении.

**Заключение.** В работе рассмотрена проблема цветовой зависимости в задачах компьютерного зрения. При обучении СНС на множестве цветных изображений, нейронная сеть может ошибочно обучиться распознавать объекты по цветовым характеристикам даже в том случае, когда цвет не определяет идентичность объектов. Это приводит к цветовой зависимости и снижению точности работы нейронной сети на множестве изображений с цветами объектов, отличными от обучающего множества.

Для решения проблемы цветовой зависимости предложен метод преобразования цветных изображений в градиентную форму. Градиентное представление удаляет информацию о цветовых составляющих пикселей и полностью сохраняет информацию о форме (геометрии) объектов.

Для градиентного представления получена формула, которая реализована в виде вычислительной нейронной сети формы. Нейросеть формы основана на блочной архитектуре, что позволяет комбинировать различные варианты вычисления векторной нормы и различные алгоритмы вычисления цветовой разности. Всего реализовано 8 функций векторной нормы и 3 алгоритма вычисления цветовой разности с использованием операторов производных Собеля, Шарра и Прюитта.

Проведен эксперимент по проверке предложенного метода устранения цветовой зависимости на задаче классификации марок автомобилей. Анализ результатов эксперимента показал, что градиентное представление изображений позволяет значительно (в 2.5 раза) снизить падение точности работы нейронной сети при изменении цветов объектов. Кроме того, применение блока формы может приводить к повышению точности работы нейронной сети за счет представления данных в более оптимальном виде и, тем самым, обуславливая выделения более подходящих признаков для распознавания геометрии объектов.

### **Библиографический список**

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. – 2-е изд., испр. – М.: ДМК Пресс, 2018. – 652 с.
2. Николенко С., Кадуринов А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – СПб.: Питер, 2018. – 480 с.
3. Chollet F. Deep Learning with Python. – NY.: Manning Publications Co., 2018. – 386 p.

4. Rosebrock A. Deep Learning for Computer Vision with Python. Starter Bundle. – pyimagesearch.com, 2017. – 332 p.
5. Rosebrock A. Deep Learning for Computer Vision with Python. Practitioner Bundle. – pyimagesearch.com, 2017. – 210 p.
6. Rosebrock A. Deep Learning for Computer Vision with Python. ImageNet Bundle. – pyimagesearch.com, 2017. – 323 p.
7. De, K. Impact of Color on Robustness of Deep Neural Networks / K. De, M. Pedersen // IEEE International Conference on Computer Vision Workshops. IEEE, 2021. P. 21-30. DOI: 10.1109/ICCVW54120.2021.00009.
8. Intriguing properties of neural networks / C. Szegedy, W. Zaremba, I. Sutskever, J. Bruna, D. Erhan, I. Goodfellow, R. Fergus / 2014. – URL: <https://arxiv.org/pdf/1312.6199.pdf> (дата обращения: 20.02.2024).
9. Kantipudi, J. Color Channel Perturbation Attacks for Fooling Convolutional Neural Networks and A Defense Against Such Attacks / J. Kantipudi, S. R. Dubey, S. Chakraborty // IEEE Transactions on artificial intelligence. IEEE, 2020. P. 181-191. – URL: <https://arxiv.org/pdf/2012.14456.pdf> (дата обращения: 20.02.2024).
10. Engilberge, M. Color representation in deep neural networks / M. Engilberge, E. Collins, S. Susstrunk // IEEE Intl. Conf. on Image Processing. IEEE 2017. P. 2786–2790. DOI: 10.1109/ICIP.2017.8296790.
11. Гладкий, С. Л. Исследование цветовой зависимости сверточных нейронных сетей в задачах компьютерного зрения / С. Л. Гладкий, С. Д. Халявин // Прикладная математика и вопросы управления. – 2024. – № 1. – С. 111–122. – DOI 10.15593/2499-9873/2024.1.07 [в печати]
12. Transparency by Design: Closing the Gap Between Performance and Interpretability in Visual Reasoning/ D. Mascharka, P. Tran, R. Soklaski, A. Majumdar / 2018. – URL: <https://arxiv.org/pdf/1803.05268> (дата обращения: 21.08.2024)
13. Saravanan, C. Color Image to Grayscale Image Conversion / C. Saravanan // Second International Conference on Computer Engineering and Applications. IEEE, 2010. P. 196-199. DOI: 10.1109/ICCEA.2010.192.
14. Bolun, C. Perception preserving decolorization / C. Bolun, X. Xiangmin, X. Xiaofen // IEEE International Conference on Image Processing. IEEE, 2018 – P. 2810-2814. DOI: 10.1109/ICIP.2018.8451303.
15. kaggle.com – Сообщество ИИ и МО. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com/datasets/prondeau/the-car-connection-picture-dataset>

## **ELIMINATING COLOR DEPENDENCY OF CONVOLUTIONAL NEURAL NETWORKS FOR COMPUTER VISION PROBLEMS**

***Sergey L. Gladkiy***

LLC «VIPAKS-Developer», Kosmonavtov av., 111, Perm, Russia, 614000,  
lrndlrnd@mail.ru

The work concerns the problem of dependency of convolutional neural networks on the color parameters of images. In the problems of image recognition when color of an object is not a valid feature, neural networks may be wrongly trained to recognize objects of some class based on its color. To solve this issue the method of eliminating color components from images suggested. The method is based on conversion color images into special gradient form. This conversion removes color components and preserves form (geometry) information. Special computational neural networks developed to evaluate gradients of color images. Then, two convolutional neural networks were trained and tested using color and gradient representation of images. The experiments proved that gradient representation removes the color dependency of trained neural networks.

**Keywords:** convolutional neural network, computational neural network, deep learning, computer vision, color dependency, image recognition.

## МЕТОД КОМПОНОВКИ РОБОТИЗИРОВАННЫХ ТЕХНОЛОГИЧЕСКИХ КОМПЛЕКСОВ НА ОСНОВЕ ОБЪЕДИНЕНИЯ СИСТЕМ КООРДИНАТ С ПРИМЕНЕНИЕМ МАШИННОГО ЗРЕНИЯ

*Холопов Владимир Анатольевич*

МИРЭА – Российский технологический университет,  
119454 г. Москва, проспект Вернадского, дом 78  
holopov@gmail.com

*Благовещенский Иван Германович*

МИРЭА – Российский технологический университет,  
119454 г. Москва, проспект Вернадского, дом 78  
igblagov@mail.ru

*Макаров Максим Алексеевич*

МИРЭА – Российский технологический университет,  
119454 г. Москва, проспект Вернадского, дом 78  
MakMak95@yandex.ru

В данной статье представлен метод компоновки роботизированного технологического комплекса (РТК) на основе объединения систем координат с применением машинного зрения и нейросетевых технологий. Предложенный подход позволяет получать точную информацию о положении и ориентации объектов в пространстве, что обеспечивает эффективное взаимодействие робота с окружающей средой и повышает точность выполнения операций.

**Ключевые слова:** машинное зрение, нейросетевые технологии, робототехнический комплекс, системы координат, глубокое обучение.

**Введение.** В современных условиях производства с высокой степенью автоматизации возрастают требования к гибкости и адаптивности производственных линий. В частности, в условиях многономенклатурного мелкосерийного производства, где задачи постоянно меняются, применение роботизированных технологических комплексов (РТК) с интегрированной системой управления становится крайне важным. Современные исследования демонстрируют значительный прогресс в интеграции машинного зрения в робототехнические комплексы, что повышает их адаптивность и эффективность [1-3], особенно в условиях многономенклатурного мелкосерийного производства. Однако, несмотря на достигнутый прогресс, вопросы эффективного объединения систем координат различных компонентов РТК остаются актуальными [4-6].

**Проблематика.** Основной проблемой при внедрении робототехнических комплексов в сложные производственные процессы является необходимость точной синхронизации всех компонентов системы. Существующие системы управления нередко работают по разрозненным координатным системам, что приводит к сложностям при переналадке оборудования и снижению общей эффективности работы комплекса. Также, многие решения в области переналадки остаются статичными и требуют значительного участия человека, что увеличивает время простоя и затраты. Текущие методы часто не учитывают

возможности динамической корректировки с использованием машинного зрения и нейросетевых технологий, что снижает их адаптивность при изменении условий производства.

**Описание работы метода.** На начальном этапе происходит инициализация системы, включающая в себя активацию компонентов РТК: роботов, конвейеров, станков с ЧПУ и систем управления. Активируются камеры и сенсоры системы машинного зрения, обеспечивающие захват изображений рабочего пространства и создание базовой модели окружающей среды.

Следующий этап метода включает сбор данных об окружающей среде с использованием машинного зрения. Этот этап состоит из следующих подэтапов:

1) Сканирование рабочего пространства, с использованием такого оборудования как RGB-камеры и ToF(Time-of-Flight)-камеры. Первый тип камер используется для распознавания объектов, а ToF-камеры для получения карты глубины. Размещение перечисленных камер индивидуально для каждого уникального участка, так как необходимо принимать в расчет требуемый обзор рабочей зоны, специфики задач и объектов, а также ограничений, связанных с оборудованием и средой.

2) Предварительная обработка данных, полученных от камер. На этом этапе проводится фильтрация изображений для удаления шумов с помощью фильтров Гаусса или медианных фильтров. Также осуществляется коррекция оптических искажений, вызванных характеристиками линз камер. После этого данные нормализуются, приводятся к стандартному формату и разрешению.

3) Выравнивание и объединение данных от разных сенсоров. Изображения с RGB-камер совмещаются с картами глубины от ToF-камер, что позволяет создать единую и более полную картину рабочего пространства. Это обеспечивает интеграцию цветовой информации с данными о глубине, что способствует более точной идентификации и классификации объектов.

4) Идентификация и классификация объектов с использованием алгоритмов компьютерного зрения и методов глубокого обучения. На данном этапе полученные от сенсоров данные анализируются для обнаружения, идентификации и классификации объектов в рабочей зоне. Применяются методы глубокого обучения, в частности сверточные нейронные сети (Convolutional Neural Networks, CNN), которые обучены на больших наборах данных, содержащих изображения различных промышленных объектов. Это позволяет системе не только определить геометрические параметры объектов (положение, ориентацию, размеры), но и их функциональное назначение, что является критически важным для последующего планирования и выполнения робототехнических операций.

После идентификации и классификации объектов мы имеем информацию о их положении и ориентации в локальной системе координат камеры. Однако компоненты РТК, такие как робот-манипулятор, работают в своих собственных локальных системах координат, что отличаются от координат камеры. Для того чтобы робот мог точно взаимодействовать с объектами (например, захватить заготовку), ему необходимо знать их положение в своей системе координат или в общей глобальной системе координат. Таким образом, объединение систем

координат является следующим логическим шагом после получения данных о положении объектов.

Для преобразования координат необходимо вычислить матрицы преобразования, которые описывают отношение между системой координат камеры и системой координат робота. Используя трансформационные матрицы, мы преобразуем положения и ориентации объектов из системы координат камеры в глобальную систему координат, что позволит взаимодействовать компонентам РТК между собой.

**Описание примера работы метода.** На первом этапе производится сбор изображений с использованием RGB-камеры и ToF-камеры. RGB-камера получает цветное изображение рабочей зоны, а ToF-камера формирует карту глубины, измеряя расстояние до каждого пикселя сцены. Перед обработкой данных проводится предварительная обработка изображений: фильтрация шумов с помощью фильтра Гаусса для сглаживания изображения и удаления высокочастотного шума, а также коррекция оптических искажений, вызванных оптикой камер, на основе параметров калибровки.

После предварительной обработки выполняется совмещение данных от RGB-камеры и ToF-камеры. Используя калибровочные данные, RGB-изображение и карта глубины совмещаются, что позволяет создать трехмерную модель рабочей зоны с цветовой информацией.

Для обнаружения и классификации объектов применяется модель нейронной сети YOLOv5. Входными данными для нейросети служит отфильтрованное RGB-изображение, а на выходе получаются координаты ограничивающих рамок объектов и их классы.

Координаты ограничивающей рамки заготовки на изображении определяются как  $(u_{min}, v_{min}, u_{max}, v_{max})$ . Центр объекта в пикселях вычисляется по формулам:

$$u_{center} = \frac{u_{min} + u_{max}}{2}, v_{center} = \frac{v_{min} + v_{max}}{2} \quad (1)$$

Глубина в точке  $(u_{center}, v_{center})$  извлекается из карты глубины  $D(u, v)$ :

$$z_{camera} = D(u_{center}, v_{center}) \quad (2)$$

Используя параметры внутренней калибровки камеры – фокусные расстояния  $f_x, f_y$  и оптический центр  $c_x, c_y$ , – координаты заготовки в системе координат камеры вычисляются следующим образом:

$$x_{camera} = \frac{(u_{center} - c_x) \cdot z_{camera}}{f_x}, y_{camera} = \frac{(v_{center} - c_y) \cdot z_{camera}}{f_y} \quad (3)$$

Результатом вычислений являются координаты заготовки  $(x_{camera}, y_{camera}, z_{camera})$  в системе координат камеры. Для преобразования этих координат в систему координат робота используется матрицы преобразования  $T_{camera\_to\_robot}$ , ко-

торая включает в себя информацию о повороте и смещении между системами координат камеры и робота. Эта матрица определяется в процессе калибровки «рука-глаз» (Hand-Eye Calibration). Преобразование координат осуществляется по формуле:

$$\begin{bmatrix} x_{robot} \\ y_{robot} \\ z_{robot} \\ 1 \end{bmatrix} = T_{camera\_to\_robot} \begin{bmatrix} x_{camera} \\ y_{camera} \\ z_{camera} \\ 1 \end{bmatrix}, \quad (4)$$

где матрица  $T_{camera\_to\_robot}$  имеет вид:

$$T_{camera\_to\_robot} = \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{32} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (5)$$

где:

- $r_{ij}$  – элементы матрицы поворота,
- $t_x, t_y, t_z$  – компоненты вектора трансляции между системами координат камеры и робота.

После преобразования координат робот использует полученные значения  $x_{robot}$ ,  $y_{robot}$ ,  $z_{robot}$  для планирования траектории движения к заготовке с учетом кинематических ограничений и возможных препятствий в рабочей зоне.

Таким образом, предложенный метод компоновки робототехнического комплекса на основе объединения систем координат с применением машинного зрения позволяет роботу эффективно взаимодействовать с объектами в рабочей зоне, обеспечивая точное позиционирование и выполнение операций.

### Библиографический список

1. Shahria, M.T.; Sunny, M.S.H.; Zarif, M.I.I.; Ghommam, J.; Ahamed, S.I.; Rahman, M.H. A Comprehensive Review of Vision-Based Robotic Applications: Current State, Components, Approaches, Barriers, and Potential Solutions. *Robotics* 2022, 11, 139. <https://doi.org/10.3390/robotics11060139>
2. Song, Li-mei & Wang, Peng-qiang & Xi, Jiang-tao & Guo, Qing-hua & Tang, Huan & Li, Jing & Li, Xiao-jie & Zhu, Teng-da. (2015). Multi-view coordinate system transformation based on robot. *Optoelectronics Letters*. 11. 473-476. 10.1007/s11801-015-5066-2.
3. Ruiz-del-Solar, Javier & Loncomilla, Patricio. (2020). Applications of Deep Learning in Robot Vision. 10.1201/9781351003827-8.
4. C. Shen et al. "Calibration algorithm in robotic remanufacturing measurement system based on 3D laser scanner." , 7384 (2009). <https://doi.org/10.1117/12.836188>.
5. G. Wang et al. "A Method of Robot Base Frame Calibration by Using Dual Quaternion Algebra." *IEEE Access*, 6 (2018): 74865-74873. <https://doi.org/10.1109/ACCESS.2018.2882502>.
6. K. On et al. "Coordinate Transformation in the Methods of Calibration of Industrial Robots." *Advances in Automobile Engineering*, 7 (2018): 1-2. <https://doi.org/10.4172/2167-7670.1000181>.

# METHOD FOR CONFIGURING A ROBOTIC TECHNOLOGICAL COMPLEX BASED ON COORDINATE SYSTEM UNIFICATION USING MACHINE VISION

***Vladimir Anatolyevich Kholopov***

MIREA – Russian Technological University,  
78 Prospect Vernadskogo, Moscow, 119454  
holopov@gmail.com

***Ivan Germanovich Blagoveshchensky***

MIREA – Russian Technological University,  
78 Prospect Vernadskogo, Moscow, 119454  
igblagov@mail.ru

***Maxim Alekseevich Makarov***

MIREA – Russian Technological University,  
78 Prospect Vernadskogo, Moscow, 119454  
MakMak95@yandex.ru

This article presents a method for configuring a Robotic Technological Complex (RTC) based on the unification of coordinate systems using machine vision and neural network technologies. The proposed approach enables the acquisition of precise information about the position and orientation of objects in space, which ensures effective interaction of the robot with its surrounding environment and increases the accuracy of operations.

**Keywords:** machine vision, neural network technologies, robotic technological complex, coordinate systems, deep learning.

УДК 004.032.26

## ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ЭТАПАХ ЖИЗНЕННОГО ЦИКЛА ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ

***Окусков Иван Сергеевич***

Санкт-Петербургский кампус Национального исследовательского университета  
«Высшая школа экономики», 194100, Россия, г. Санкт-Петербург,  
Кантемировская ул., д. 3, корп. 1, лит. А  
iokuskov@hse.ru

Материал анализирует применение ИИ на разных этапах жизненного цикла разработки ПО (SDLC). Рассматриваются примеры автоматизации задач, таких как анализ требований, проектирование, разработка, тестирование и сопровождение систем. ИИ эффективно справляется с рутинными задачами, но на этапах, где требуется креативность и глубокое понимание бизнес-контекста, его роль остается вспомогательной. Несмотря на успехи, ИИ пока не может заменить человека в решении сложных задач.

**Ключевые слова:** искусственный интеллект, SDLC, автоматизация, анализ требований, тестирование программного обеспечения, сопровождение систем.

**Введение.** С развитием технологий искусственного интеллекта (ИИ) и машинного обучения (ML) их применение в различных областях информационных технологий становится все более значимым. Одной из таких областей



является жизненный цикл программного обеспечения (SDLC), который охватывает полный спектр этапов от концепции и проектирования до тестирования, внедрения и сопровождения программных систем. Традиционные подходы к разработке ПО, такие как каскадная модель и гибкие методологии (Agile, Scrum), значительно улучшили процессы управления разработкой. Однако, с усложнением программных систем и увеличением объема данных, организации сталкиваются с проблемами, связанными с качеством, безопасностью и эффективностью разработки программного обеспечения, что открывает новые возможности для применения ИИ.

Искусственный интеллект уже успешно используется для решения задач управления дефектами, предсказания уязвимостей, автоматизации тестирования и анализа больших объемов данных в программной инженерии [6]. Например, методы машинного обучения и обработки естественного языка (NLP) позволяют автоматизировать анализ требований, улучшать процессы кодирования и тестирования, а также прогнозировать возможные ошибки на ранних этапах разработки. Включение ИИ в такие процессы, как классификация дефектов и предсказание уязвимостей, демонстрирует улучшение качества программных продуктов, что подтверждается результатами исследования на примере крупных компаний [11].

Кроме того, гибридные модели разработки, сочетающие традиционные и современные подходы, такие как каскадная модель и Agile, открывают дополнительные возможности для внедрения ИИ на каждом этапе жизненного цикла программного обеспечения. Применение таких подходов способствует трансформации систем управления качеством и позволяет достигать более высоких показателей эффективности, улучшая процесс управления данными и дефектами [11].

В данном материале исследуется применение искусственного интеллекта на различных этапах жизненного цикла программного обеспечения.

**Выборка материалов.** Для формирования выборки научных статей по тематикам (искусственный интеллект и жизненный цикл разработки программного обеспечения) были использованы следующие критерии. Ключевые слова “AI AND SDLC” (1), годы публикации с 2020 по 2024 (2), предметные области “Computer science” и “Business, Management and Accounting”. Выборка по таким параметрам составила 62 статьи. Детальный анализ на предмет упоминания применения ИИ на этапах SDLC позволил выбрать для дальнейшей работы 15 статей.

**Анализ применения ИИ на этапах жизненного цикла программного обеспечения.** Использование искусственного интеллекта (ИИ) на различных этапах жизненного цикла разработки программного обеспечения (SDLC) предоставляет значительные преимущества, однако степень его применения варьируется в зависимости от сложности задач и уровня формализации этапов. Рассмотрим это более детально.

**Планирование:** Этот этап SDLC традиционно зависит от человеческой экспертизы, поскольку включает в себя стратегическое видение, определение бизнес-целей и разработку дорожной карты проекта. В рассматриваемых статьях не отмечено активного применения ИИ на этапе планирования, что можно объяснить высокой неопределенностью и слабой структурированностью задач.

Тем не менее, в будущем можно ожидать появления инструментов ИИ для поддержки принятия решений, анализа рисков и ресурсного планирования, особенно в контексте больших данных и прогнозирования тенденций.

**Анализ требований:** Этап анализа требований является ключевым, поскольку ошибки, допущенные на этом этапе, могут существенно увеличить затраты на исправления на последующих стадиях. ИИ используется для автоматической трассировки связей между требованиями и выявления потенциальных несоответствий. Это позволяет снизить риски ошибок, повышая качество анализа и делая его более предсказуемым. Применение ИИ в этой области может значительно улучшить понимание требований, особенно в условиях слабоструктурированных проблем, где требования часто меняются и нуждаются в постоянной корректировке.

**Проектирование:** использование ИИ для автоматической генерации схем проектирования на основе требований демонстрирует его потенциал к сокращению временных затрат на этом этапе. Автоматизация проектирования позволяет инженерам сосредоточиться на более творческих и сложных задачах, оставляя рутинные процессы ИИ. Тем не менее, в проектировании все еще необходим человеческий контроль, поскольку система не всегда способна учесть все нюансы, особенно при разработке уникальных решений.

**Разработка:** на этапе разработки ИИ часто применяется для автоматической генерации кода. Это особенно полезно в повторяющихся или типовых задачах, где алгоритмы ИИ могут ускорить процесс и минимизировать количество ошибок. Однако разработка критически важных систем или сложных компонентов все еще требует вмешательства человека, так как ИИ пока не способен самостоятельно решать задачи с высокой степенью неопределенности и сложностью, где требуется творческое мышление и инновационный подход.

**Тестирование:** это один из этапов SDLC, где ИИ демонстрирует наибольшую эффективность. Алгоритмы ИИ используются для предсказания дефектов, автоматизации тестов и улучшения их качества. ИИ способен выявлять уязвимости на основе анализа исходного кода и предсказывать потенциальные проблемы, что существенно сокращает время на тестирование и повышает надежность ПО. Дальнейшее развитие ИИ в этой области может привести к полному переходу на автоматизированное тестирование, минимизируя участие человека.

**Внедрение:** на этапе внедрения ИИ применяется для оптимизации кода и автоматической настройки систем. Это позволяет ускорить процесс интеграции и повысить производительность разрабатываемых систем. Однако внедрение все еще остается сложной задачей, требующей учета множества факторов, включая инфраструктурные и бизнес-аспекты, что пока ограничивает полную автоматизацию этого этапа.

**Эксплуатация и сопровождение:** в пост-продакшн среде ИИ играет важную роль в мониторинге производительности и предсказании возможных сбоев. Анализ исторических данных позволяет выявлять закономерности в работе системы и своевременно предсказывать потребности в обновлении или ремонте. Это особенно полезно для масштабируемых и сложных систем, где человеческий контроль за всеми процессами практически невозможен.

**Выводы из анализа применения ИИ на этапах жизненного цикла программного обеспечения.** Прежде всего, применение ИИ на этапах планирования и анализа требований остается ограниченным. Это связано с тем, что данные этапы предполагают работу с высокой степенью неопределенности и требуют не только структурированного подхода, но и глубокого понимания контекста, бизнес-целей и стратегических приоритетов. ИИ на этих стадиях может играть вспомогательную роль, предоставляя инструменты для анализа рисков или работы с большими объемами данных, но основную ответственность за принятие решений несут люди. В будущем мы можем ожидать развития ИИ-инструментов, способных оказывать более значимую поддержку на этих этапах, особенно в условиях многовариантности сценариев и необходимости динамического анализа.

На этапах проектирования и разработки ИИ уже сегодня демонстрирует свою эффективность в автоматизации рутинных и повторяющихся задач, таких как генерация кода и проектирование типовых решений. Однако сложные системы, требующие инновационного подхода и нестандартных решений, по-прежнему нуждаются в человеческом участии. Это объясняется тем, что ИИ пока не может заменить креативное и интуитивное мышление, необходимые для разработки уникальных программных решений. Тем не менее, с увеличением объема данных и возможностей для их обработки, ИИ сможет всё более успешно поддерживать процессы проектирования, помогая разработчикам лучше справляться с масштабными проектами и сложными системами.

Самые заметные успехи ИИ наблюдаются на этапе тестирования, где автоматизация тестов, предсказание дефектов и выявление уязвимостей стали важными инструментами для повышения эффективности и точности тестовых процессов. Это позволяет значительно сокращать время на тестирование, одновременно улучшая качество выпускаемого продукта. Более того, использование ИИ для автоматизации тестов не только снижает временные и трудовые затраты, но и повышает степень надежности программного обеспечения, что особенно важно в условиях сложных и многокомпонентных систем.

Этап внедрения программного обеспечения также выигрывает от применения ИИ, который помогает оптимизировать код и автоматизировать процессы настройки и интеграции систем. Тем не менее, полностью автоматизировать этот этап пока не представляется возможным, так как внедрение требует учета множества факторов, включая адаптацию к специфическим бизнес-процессам и инфраструктуре. Здесь ИИ может играть вспомогательную роль, но окончательные решения и их реализация остаются за командами разработчиков и системных интеграторов.

Что касается этапа эксплуатации и сопровождения, ИИ демонстрирует высокий потенциал в автоматизации анализа работы систем, предсказании сбоев и управлении обновлениями. Анализ больших объемов данных, собранных в процессе эксплуатации, позволяет системам на основе ИИ выявлять аномалии и предлагать меры по предотвращению отказов или снижения производительности. Это особенно важно в условиях высоконагруженных и сложных систем, где человеческий контроль за всеми аспектами эксплуатации невозможен.

В заключение можно отметить, что ИИ значительно расширяет возможности автоматизации и повышения эффективности на различных этапах SDLC, особенно там, где процессы можно четко формализовать и структурировать. Однако, несмотря на впечатляющие успехи, ИИ еще не в состоянии заменить человека на ключевых этапах разработки, таких как планирование, анализ требований и проектирование, где требуется комплексное понимание, креативность и способность адаптироваться к изменяющимся условиям. В будущем развитие ИИ-технологий в области обработки естественного языка, глубокого обучения и анализа данных, вероятно, позволит преодолеть некоторые из этих ограничений, однако роль человека остается критически важной в процессе разработки ПО. Оптимальное использование ИИ будет заключаться в его интеграции как вспомогательного инструмента, дополняющего человеческую экспертизу и усиливающего способности команд разработчиков в решении сложных задач.

### Библиографический список

1. Mohammad Amin Kuhail и др., «“Will I be replaced?” Assessing ChatGPT’s effect on software development and programmer perceptions of AI tools», *Science of Computer Programming* 235 (1 июль 2024 г.): 103111, <https://doi.org/10.1016/j.scico.2024.103111>.
2. Jalaj Pachouly и др., «A systematic literature review on software defect prediction using artificial intelligence: Datasets, Data Validation Methods, Approaches, and Tools», *Engineering Applications of Artificial Intelligence* 111 (1 май 2022 г.): 104773, <https://doi.org/10.1016/j.engappai.2022.104773>.
3. Panchanan Nath и др., «AI and Blockchain-based source code vulnerability detection and prevention system for multiparty software development», *Computers and Electrical Engineering* 106 (1 март 2023 г.): 108607, <https://doi.org/10.1016/j.compeleceng.2023.108607>.
4. Ehsan Mashhadi и др., «An empirical study on bug severity estimation using source code metrics and static analysis», *Journal of Systems and Software* 217 (1 ноябрь 2024 г.): 112179, <https://doi.org/10.1016/j.jss.2024.112179>.
5. Bangchao Wang и др., «An empirical study on the state-of-the-art methods for requirement-to-code traceability link recovery», *Journal of King Saud University – Computer and Information Sciences* 36, вып. 6 (1 июль 2024 г.): 102118, <https://doi.org/10.1016/j.jksuci.2024.102118>.
6. Padmalata Nistala и др., «An industrial experience report on model-based, AI-enabled proposal development for an RFP/RFI», *Science of Computer Programming* 233 (1 март 2024 г.): 103058, <https://doi.org/10.1016/j.scico.2023.103058>.
7. Andrey Sadovykh и др., «An iterative approach for model-based requirements engineering in large collaborative projects: A detailed experience report», *Science of Computer Programming* 232 (1 январь 2024 г.): 103047, <https://doi.org/10.1016/j.scico.2023.103047>.
8. Zaki Pauzi и Andrea Capiluppi, «Applications of natural language processing in software traceability: A systematic mapping study», *Journal of Systems and Software* 198 (1 апрель 2023 г.): 111616, <https://doi.org/10.1016/j.jss.2023.111616>.
9. Changiz Valmohammadi и Farkhondeh Mortaz Hejri, «Designing a conceptual green process model in software development: A mixed method approach», *International Journal of Information Management Data Insights* 3, вып. 2 (1 ноябрь 2023 г.): 100204, <https://doi.org/10.1016/j.jjime.2023.100204>.
10. Siri Padmanabhan Poti и Christopher J Stanton, «Enabling affordances for AI Governance», *Journal of Responsible Technology* 18 (1 июнь 2024 г.): 100086, <https://doi.org/10.1016/j.jrt.2024.100086>.
11. Satya Pradhan и Venky Nanniyur, «Large scale quality transformation in hybrid development organizations – A case study», *Journal of Systems and Software* 171 (1 январь 2021 г.): 110836, <https://doi.org/10.1016/j.jss.2020.110836>.
12. Abdulrahman Alzahrani и Rafiq Ahmad Khan, «Secure software design evaluation and decision making model for ubiquitous computing: A two-stage ANN-Fuzzy AHP approach», *Computers in Human Behavior* 153 (1 апрель 2024 г.): 108109, <https://doi.org/10.1016/j.chb.2023.108109>.
13. Janaka Senanayake и др., «Defendroid: Real-time Android code vulnerability detection via blockchain federated neural network with XAI», *Journal of Information Security and Applications* 82 (1 май 2024 г.): 103741, <https://doi.org/10.1016/j.jisa.2024.103741>.

14. Katarzyna Biesialska, Xavier Franch, и Victor Muntés-Mulero, «Big Data analytics in Agile software development: A systematic mapping study», *Information and Software Technology* 132 (1 апрель 2021 г.): 106448, <https://doi.org/10.1016/j.infsof.2020.106448>.

15. Cataldo Basile и др., «Design, implementation, and automation of a risk management approach for man-at-the-End software protection», *Computers & Security* 132 (1 сентябрь 2023 г.): 103321, <https://doi.org/10.1016/j.cose.2023.103321>.

## APPLICATION OF ARTIFICIAL INTELLIGENCE IN THE STAGES OF THE SOFTWARE DEVELOPMENT LIFECYCLE

*Ivan S. Okuskov*

Saint Petersburg Campus, National Research University Higher School of Economics,  
194100, Russia, St. Petersburg, Kantemirovskaya St., 3  
[iokuskov@hse.ru](mailto:iokuskov@hse.ru)

This paper provides an analysis of the application of artificial intelligence (AI) across various stages of the Software Development Lifecycle (SDLC). It explores the automation of tasks such as requirements analysis, design, development, testing, and system maintenance. While AI demonstrates significant efficiency in handling routine and repetitive tasks, its role remains largely supportive in stages that require creativity and deep comprehension of the business context. Despite advancements, AI is not yet able to fully replace human expertise in addressing complex, ill-structured problems.

**Keywords:** artificial intelligence, SDLC, automation, requirements analysis, software testing, system maintenance.

УДК 004.932.2

## УЛУЧШЕНИЕ ВИДИМОСТИ ОБЪЕКТОВ НА ИЗОБРАЖЕНИИ ПРИ ПОМОЩИ НЕЙРОСЕТИ

*Сапегин Арсений Антонович*

Национальный исследовательский Томский политехнический университет,  
634050, Россия, г. Томск, ул. Ленина, 30  
[aas271@tpu.ru](mailto:aas271@tpu.ru)

В статье представлено описание разработки алгоритма на основе нейросетевого подхода восстановления изображения с неравномерным освещением для улучшения видимости объектов.

**Ключевые слова:** нейросетевые технологии, сверточные нейросети, нормализация яркости, видимость объектов, улучшение контраста.

**Введение.** Несмотря на то, что возможности машинного обучения с каждым годом только растут, еще долгое время вопрос о полной замене человека-оператора на полностью автоматическую систему останется как минимум дискуссионным. Не смотря на отсутствие у искусственного интеллекта «человеческого фактора», компьютер подвержен возможности неверной интерпретации данных. Особенно этот вопрос щепетилен в области анализа изображений и видеонаблюдения. Даже при имеющейся имитации когнитивных функций, ИИ не способен правильно интерпретировать некоторые наборы признаков.

Рациональным путем в таком случае может стать внедрение системы, которая не принимает решения, а только указывает операторам-людям на факт совершения тех или иных нарушений. Однако в данном случае мы сталкиваемся с несовершенством человеческого восприятия.

Частая проблема, которая возникает при просмотре человеком изображений, является затруднение в распознавании объектов в особо темных зонах или областях с пересветами. Подобные ситуации сильно влияют на оперативность принятия решений. Хорошо обученная нейронная сеть способна распознавать образы даже при плохой видимости. Для человека же может стать критичным, если интенсивность пикселей, которые формируют объект, недостаточно отличается от интенсивности пикселей фона.

Таким образом, может образоваться патовая ситуация, когда сеть наблюдает тот паттерн, на который была натренирована, но оператору уже трудно его распознать. Это может привести к игнорированию со стороны человека предупреждения от ИИ.

Необходимо произвести дополнительную коррекцию видеопотока. Для подобных целей предусмотрены алгоритмы восстановления неравномерно освещенных изображений. Однако стандартные методы обладают рядом определенных недостатков. Основная цель работы – разработка подхода, который бы решал проблему плохой видимости объектов в автоматическом порядке.

#### **Описание стандартных способов восстановления изображений.**

Самыми популярным подходами к улучшению контраста изображения можно считать Multi-Scale Retinex (MSR) [1] и Histogram Equalization (HE) [2].

MSR основан на принципах восприятия человеческим глазом и представляет собой модификацию Single-Scale Retinex (SSR). Суть этого метода заключается в работе с локальной освещенностью, которая вычисляется при помощи применения пространственных фильтров (чаще всего гауссового). После выделения локальных компонент, значения пикселей изображения корректируются с учетом уменьшенной локальной освещенности, что позволяет улучшить контраст и четкость. MSR сочетает результаты обработки SSR с разными параметрами, что дает более естественные и визуально привлекательные результаты. Однако тем самым это приводит к получению огромного количества переменных, которые должны подбираться для каждого изображения в индивидуальном порядке.

HE – это метод улучшения контрастности изображения, при котором распределение яркости преобразуется так, чтобы равномерно заполнять весь диапазон значений. Этот процесс включает в себя вычисление гистограммы изображения, нахождение кумулятивной распределенной функции и применение её для перераспределения пикселей, что позволяет выделить детали в тенях и светах и улучшить визуальное восприятие изображения. Существуют множество вариаций и модификаций HE, и зачастую они менее эффективны, чем MSR, однако при этом требуют гораздо меньшего вмешательства со стороны человека.

**Описание нейросетевого подхода.** Суть разработанного подхода сводится к использованию архитектуры сверточной нейронной сети Super-Resolution Convolutional Neural Network (SRCNN) [3]. Данная архитектура предназначена для минимизации потери качества увеличенного через бикубическую интерполя-

цию изображения. Разработанный подход заключается в переобучении нейросети на задачу адаптивного улучшения контраста объектов на каком-либо фоне.

Для этого было необходимо модернизировать исходную архитектуру путем увеличения входных сигналов. Если оригинальная SRCNN получала на вход только изображение, которое ей необходимо было обработать, то модификация помимо него анализирует вариации исходника, которые были улучшены стандартными методами (SSR и HE).

**Формирование датасета.** В задаче улучшения видимости объекта в первую очередь вы сталкиваетесь со сложностью формирования тренировочных данных и оценки результатов. Помимо того, что изображение-эталон должно быть хорошо освещено и не иметь слепых зон (включая пересвет), так как иллюстрирует идеальную ситуацию, так и необходимо найти ее «испорченную» версию. Т.е. в обеих версиях объекты должны быть на одном месте, пиксель в пиксель, но при этом иметь разные условия съемки.

На текущий момент, самым оптимальным подходом является использование датасетов для обучения более сложных сетей, которые предназначены для полного удаления теней. Необходимо брать малые фрагменты изображений (64x64) и подвергать их дополнительной аугментации (в виде манипуляций с яркостью и контрастом) для формирования входных изображений. Главный недостаток такого подхода заключается в том, что сеть обрабатывает реальные тени и искусственные пересветы. Тем самым, с задачей уменьшения яркости там, где это надо, она справляется хуже, чем с обратным процессом.

**Обучение и тестирование нейросети.** Задача видимости объекта весьма специфична, и стандартные метрики качества изображений не подходят для нее. Оценка Мунтеану-Роса (MR) [4] основана на том свойстве, что для человеческого восприятия большее значение имеет перепад яркости в соседних пикселях, чем значение яркости в каждом пикселе. В то же время равномерность гистограммы изображения также положительно сказывается на восприятии изображения. Однако MR «поощряет» слишком резкие изображения, из-за чего пришлось модифицировать данную метрику, путем ввода штрафа за сильное структурное отличие от оригинала [5].

Для проведения оценивания качества работы разработанных алгоритмов были выбраны изображения из Contrast Enhancement Evaluation Database. Данный набор содержит несколько оригинальных изображений и их обработанные разными методами версии. Подразумевается, что для каждого изображения подбирались лучшие параметры каждого метода. Тем самым разработанные алгоритмы должны сравниваться с лучшими результатами обработки. Из имеющихся подготовленных методов были выбраны самые лучшие: GHE (Global Histogram Equalization) и MSR.

В рамках выбранного датасета средняя оценка MR составляла 201 для оригинальных изображений, 253 для результатов обработки GHE и 260 – для MSR. Ровно столько же получили и результаты обработки нейросети. Т.е. разработанный подход сравнивался с MSR. Однако стоит понимать, что в случае MSR вручную подбирались параметры для каждого изображения, в то время как нейросеть смогла добиться такого результата автоматически. На рисунке показан пример обработки изображений разными алгоритмами.




Рис. Сравнение результатов работы методов

**Заключение.** В процессе исследования были разработаны различные методы адаптации SRCNN, направленные на восстановление неравномерно освещенных снимков. Был сформирован алгоритм, решающий задачу улучшения видимости объектов на фоне. Одним из основных преимуществ алгоритма является его полная автономия в обработке изображений. Качество получаемых изображений не уступает результатам методов, требующих ручной настройки параметров.

### Библиографический список

1. Parthasarathy S, Sankaran P. An automated multi Scale Retinex with Color Restoration for image enhancement // Текст : электронный // ResearchGate. – 2012. – URL: [https://www.researchgate.net/publication/254024214\\_An\\_automated\\_multi\\_Scale\\_Retinex\\_with\\_Color\\_Restoration\\_for\\_image\\_enhancement](https://www.researchgate.net/publication/254024214_An_automated_multi_Scale_Retinex_with_Color_Restoration_for_image_enhancement)
2. Гонсалес Р., Вудс Р. Цифровая обработка изображений. – Москва: Техносфера, 2005. – 1072 с.
3. Liu Xiangchun<sup>1</sup>, Chen Zhan<sup>1</sup>, Song Wei, Li Fenglei<sup>1</sup>, Yang Yanxing, «Data Matching of Solar Images Super-Resolution Based on Deep Learning», «Computers, Materials & Continua», March 2021
4. Munteanu C., Rosa A. Gray-scale image enhancement as an automatic process driven by evolution // IEEE Trans. on Systems, Man, and Cybernetics – part B: Cybernetics. – 2004. – Vol. 34. № 2.
5. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E. P Image Quality Assessment: From Error Visibility to Structural Similarity // IEEE Trans. Image Process. – 2004. – Vol. 13 № 4 – P. 2–15.

## IMPROVING THE VISIBILITY OF OBJECTS IN THE IMAGE USING A NEURAL NETWORK

*Arseniy G. Sapegin*

Tomsk Polytechnic University,  
Russia, Tomsk, Lenin str., 30, 634050  
aas271@tpu.ru

The article describes the development of an algorithm based on a neural network approach for image reconstruction with uneven illumination to improve the visibility of objects.

**Keywords:** neural network technologies, convolutional neural networks, brightness normalization, object visibility, contrast improvement.



## **ТЕОРЕТИЧЕСКИЕ И ПРАКТИЧЕСКИЕ АСПЕКТЫ ПОСТРОЕНИЯ РЕКОМЕНДАТЕЛЬНЫХ МОДЕЛЕЙ: ТИПОЛОГИЯ, АРХИТЕКТУРА И НАПРАВЛЕНИЯ ПРОЕКТИРОВАНИЯ**

***Соколов Андрей Валерьевич***

АНО ВО «Университет Иннополис»,  
420500, Россия, г. Иннополис, ул. Университетская, 1  
and.sokolov@innopolis.university, asokolov@interprogram.ru

***Сычев Иван Андреевич***

Национальный исследовательский университет  
Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
isychev@interprogram.ru

***Хейфец Илья Игоревич***

Национальный исследовательский университет  
Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
kheyfetz@psu.ru

***Соколова Ольга Леонидовна***

Национальный исследовательский университет  
Пермский государственный национальный исследовательский университет,  
614068, Россия, г. Пермь, ул. Букирева, 15  
otoropova@interprogram.ru

В условиях современного динамичного мира проблематика экономии временных ресурсов становится особенно актуальной. Одним из перспективных подходов к решению этой задачи является использование систем рекомендации в рамках различных цифровых сервисов и платформ. Однако, как показывает исследование, в существующих системах предварительного заказа и доставки товаров данная проблема все еще остается нерешенной или решается недостаточно [1-3]. В настоящей статье рассматриваются типы современных рекомендательных систем, возможности применения их алгоритмов и выделение основных направлений в проектировании архитектуры системы, способной к интеграции на платформу для предварительного заказа товаров и услуг.

**Ключевые слова:** рекомендательные системы, системы рекомендаций, нейронные сети, рекуррентная нейронная сеть, алгоритмы рекомендательных систем, многослойный перцептрон, сверточная нейронная сеть, графовая нейронная сеть.

**Введение.** Целью работы является обзор и анализ существующих рекомендательных систем, их алгоритмов и выделение основных тенденций и возможных направлений с целью проектирования рекомендательной системы для сервиса предзаказа и доставки, учитывающей все доступные данные и непрерывно обучающуюся, предлагающую не только рекомендации аналогичных товаров или услуг, но и прогнозируя виды позиций, которые могут заинтересовать пользователя. Кроме того, система должна быть адаптирована для пуска при холодном старте.

**Обзор типов существующих рекомендательных систем.** Наиболее точное, на наш взгляд, описание типов рекомендательных систем представлено в

работе [4]. В статье классифицируют рекомендательные системы в соответствии с четырьмя типами:

1. Контент-ориентированная рекомендательная система или система с фильтрацией содержимого сравнивает предпочтения пользователя по двум направлениям, как по профилю пользователя, так и по профилю объекта [5].

2. Коллаборативная рекомендательная система представляет собой алгоритм, который сопоставляет профиль пользователя с профилями других пользователей, определяя профили с аналогичными предпочтениями, и предполагает, что выявленные предпочтения могут быть полезными для данного пользователя.

3. Система рекомендаций, основанная на знаниях, относится к типу рекомендательных систем, основанных на предварительных знаниях о предпочтениях пользователя, как в контексте контент-ориентированного подхода, так и коллаборативного. Подход требует наличия исторических данных [6].

4. Гибридная рекомендательная система может сочетать в себе различные типы систем, описанные выше, или использовать их комбинацию.

Особенную сложность вызывает проектирование рабочих процессов системы на “холодном старте” – первоначальном построении и обучения систем, когда еще нет исторических данных о предпочтениях пользователей или информации о покупках, что является одной из ключевых проблем. Для оптимизации процесса холодного старта могут быть использованы следующие механизмы:

1. адаптивное обучение – рекомендательная система может обучаться на основе обратной связи от пользователей;

2. коллаборативная фильтрация на основе демографических данных, которые пользователи указывают при регистрации [7];

3. гибридные механизмы, когда различные методы могут быть объединены для улучшения точности и стабильности предсказаний.

Кроме того, авторы готовы протестировать гипотезу о возможном влиянии времени года, месяца рождения и знака зодиака пользователя на его предпочтения при выборе того или иного блюда на холодном старте системы. Внедрение нейронных сетей, успешно использующих в своих механизмах данные о знаках зодиака пользователей [8], позволяет предположить, что тестирование подобной гипотезы не лишено смысла.

#### **Актуальные модели рекомендаций сервисов предзаказа и доставки.**

В соответствии с регламентами использования рекомендательных систем, Яндекс Еда и Маркет Деливери используют следующие данные пользователя: исторический отчет о заказах, геопозицию, рейтинг доступных пунктов питания и время доставки из этих пунктов [9].

Сервис быстрой доставки продуктов Самокат использует следующие данные о пользователе: товары в корзине пользователя, заказанные ранее товары и время заказа через сервис [10]. По результатам применения рекомендательных технологий сервис предлагает подборки товаров: блоки, состоящие из ранее заказанных пользователем товаров; товарные подборки с похожими, сопутствующими и дополнительными товарами; товарные подборки с персональными рекомендациями, маркетинговыми товарами и скидками.

Сервис доставки продуктов и товаров для дома СберМаркет использует рекомендации двух типов: персонализированные и не персонализированные

[11]. Сервис использует следующие данные о пользователе: уже приобретенные через сервис товары, просмотренные на сервисе товары.

После изучения представленных сервисами правил применения рекомендательных технологий, были определены типы используемых рекомендательных систем, представленные в табл.

Таблица

**Типы рекомендательных систем**

Сервис	Основанная на контенте	Коллаборативный тип	Основанная на знаниях	Гибридная
Яндекс Еда	+	+	-	-
Деливери Маркет	+	+	-	-
Самокат	+	-	-	-
Сбер Маркет	+	-	+	+

Таким образом, Яндекс Еда, Деливери Маркет и СберМаркет используют гибридные модели. Самокат в основном использует рекомендательную систему, основанную на контенте. Особенности подборки в крупной розничной сети «Лента» во многом схожи с рекомендационной моделью Самоката [12].

#### **Обзор архитектур рекомендательных систем**

Модель Wide and Deep [13] состоит из двух компонентов: «Широкого» и «Глубокого». «Широкий» компонент предназначен для обработки большого количества признаков и событий, а «Глубокий» – для обработки сложных взаимосвязей между признаками.

Общая идея модели NeuralCollaborativeFiltering (NCF) заключается в том, что нейронная сеть, теоретически, может усвоить любую функциональную зависимость. NCF предлагает простой слой представления сразу для пользователей и объектов, за которым следует простая нейронная сеть вроде многослойного перцептрона, которая должна усвоить зависимость между представлениями пользователя и объекта, аналогичную произведению факторизованных матриц [14].

Deep Factorization Machine (DeepFM) [15] состоит из машины факторизации для рекомендаций и глубокого обучения для изучения функций, сочетает в себе их возможности. Модель способна автоматически извлекать сложные взаимодействия между признаками, а также учитывать взаимодействия различных порядков, что позволяет учитывать линейные и нелинейные зависимости.

NeuralFactorizationMachines [16] – эта модель объединяет эффективность машин линейной факторизации с высокой способностью представления нелинейных нейронных сетей для разреженного прогнозирующего анализа. Ключом к его архитектуре является операция, называемая объединением билинейных взаимодействий, которая позволяет модели нейронной сети изучать более информативные взаимодействия объектов на более низком уровне.

Multi-ComponentGraphConvolutionalCollaborativeFiltering (MCCF) [17] является одним из подходов, который изучает скрытую мотивацию покупки с помощью механизма привлечения внимания и сочетает ее с функциями явного взаимодействия пользователя с товаром для получения лучших рекомендаций.

Системы рекомендаций на основе сессий (Session-based Recommender Systems) анализируют краткосрочные предпочтения пользователей и динамику их изменения [18]. Рассматривая каждую сессию в качестве базовой единицы входных данных, SBRS может выявлять как краткосрочные предпочтения пользователя из его последних сессий, так и динамику его предпочтений, отражающую изменение его предпочтений от сессии к сессии.

Проектирование системы рекомендаций. С учетом необходимости учитывать краткосрочные предпочтения для рекомендации товаров был сделан выбор в пользу систем рекомендаций на основе сессий. Доступны следующие входные данные: информация о пользователях: дата рождения, текущее местоположение, информация о товарах: категория товара, цена, доступность самовывоза, время приготовления, идентификатор заведения, информация о заведениях: адрес, время работы, оценки пользователей, тип заведения, информация о местоположении и текущем времени: на основе местоположения рассчитывается расстояние до заведения и время доставки или проезда, текущее время может помочь рекомендовать товары с учетом потребностей пользователя в разное время суток, информация о взаимодействии пользователя с товарами: оценка товара пользователем, просмотр, добавление в корзину, заказ товара пользователем, информация о взаимодействии пользователя с заведением: оценка заведения пользователем, просмотр.

**Заключение.** В данной статье были рассмотрены теоретические и практические аспекты построения рекомендательных моделей, их типология, архитектура и направления проектирования. Также был представлен обзор архитектур рекомендательных систем и освещены основные этапы проектирования системы рекомендаций. Авторы выделили основные направления в проектировании архитектуры рекомендательной системы, которые могут быть применимы для интеграции на платформы предварительного заказа и доставки, такие как использование коллаборативной фильтрации, анализ поведения пользователей, применение машинного обучения и построение семантических сетей.

### Библиографический список

1. Yuanzhe Peng. A Survey on Modern Recommendation System Based on Big Data // Cornell University, 2022
2. Сейдаметова З.С. Системы рекомендаций в электронной коммерции / З.С. Сейдаметова // Ученые записи Крымского инженерно-педагогического университета. – 2018. – № 3(61). – С. 121-127. Меньшикова Н.В., Портнов И.В., Николаев И.Е. / Обзор рекомендательных систем и возможности учета контекста при формировании индивидуальных рекомендаций // Academy. – 2016. – № 6(9). – С. 22
3. Меньшикова Н.В., Портнов И.В., Николаев И.Е. / Обзор рекомендательных систем и возможности учета контекста при формировании индивидуальных рекомендаций // Academy. – 2016. – № 6(9). – С. 22
4. A SURVEY ON MODERN RECOMMENDATION SYSTEM BASED ON BIG DATA, Yuanzhe Peng, Department of Electrical and Computer Engineering, University of Miami
5. Эволюция рекомендаций ресторанов в Delivery Club. Часть 1 // Хабр: [сайт] – 2018. – RL: <https://habr.com/ru/companies/deliveryclub/articles/656505/> (дата обращения: 18.11.2023)
6. Salunke, Tanmayee&Nichite, Unnati. (2022). Recommender Systems in E-commerce. 10.13140/RG.2.2.10194.43202.
7. Рекомендательная система: введение в проблему холодного старта // Хабр: [сайт] – 2013. – RL: <https://habr.com/ru/companies/surfinbird/articles/168733/> (дата обращения: 18.11.2023)

8. Ясницкий Леонид Нахимович, Петров Аскольд Маркович, Сичинава Зураби Иродиевич Сравнительный анализ алгоритмов нейросетевого детектирования лжи // Известия вузов. Поволжский регион. Технические науки. 2010. №1. URL: <https://cyberleninka.ru/article/n/sravnitelnyy-analiz-algoritmov-neyrosetevogo-detektirovaniya-lzhi> (дата обращения: 20.11.2023).
9. Яндекс Правовые Документы: официальный сайт – URL: [https://yandex.ru/legal/recommendations/#index\\_\\_eats](https://yandex.ru/legal/recommendations/#index__eats) (дата обращения: 20.11.2023).
10. Самокат. Правила применения рекомендательных технологий: официальный сайт – URL: [https://samokat.ru/static/legal/recommendation\\_technologies\\_policy.html](https://samokat.ru/static/legal/recommendation_technologies_policy.html) (дата обращения: 20.11.2023).
11. Сбер Маркет. Правила применения рекомендательных технологий: официальный сайт – URL: <https://sbermarket.ru/sp/recommendations> (дата обращения 21.11.2023).
12. Лента. Правила применения рекомендательных технологий: официальный сайт – URL: <https://lenta.com/pokupatelyam/recommendation-technologies/> (дата обращения 21.11.2023).
13. Wide and Deep Learning for Recommender Systems. Heng-Tze Cheng, Levent Koc, Jeremiah Harmsen, Tal Shaked, Tushar Chandra, Hrishikesh Aradhye, Glen Anderson, Greg Corrado, Wei Chai, Mustafa Ipsir, Rohan Anil, Zakaria Haque, Lichan Hong, Vihan Jain, Xiaobing Liu, and Hemal Shah. June 2016
14. Neural Collaborative Filtering. Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, and Tat-Seng Chua. August 2017
15. DeepFM: A Factorization-Machine based Neural Network for CTR Prediction. Huifeng Guo, Ruiming Tang, Yunming Ye, Zhenguo Li, and Xiuqiang He. March 2017.
16. He, Xiangnan & Chua, Tat-Seng. (2017). Neural Factorization Machines for Sparse Predictive Analytics.
17. Xiao Wang, Ruijia Wang, Chuan Shi, Guojie Song, Qingyong Li (2019). Multi-Component Graph Convolutional Collaborative Filtering
18. Якупов Д.Р., Намиот Д.Е. Рекомендательные системы на основе сессий – модели и задачи // International Journal of Open Information Technologies. 2022. №7. – С. 128-152.

## THEORETICAL AND PRACTICAL ASPECTS BUILDING RECOMMENDATION MODELS: TYPOLOGY, ARCHITECTURE AND DIRECTIONS DESIGN

***Andrey V. Sokolov***

Innopolis University,  
Str. Universitetskaya, 1, Innopolis, Respublika Tatarstan, 420500  
and.sokolov@innopolis.university, asokolov@interprogram.ru

***Ivan A. Sychev***

Perm State National Research University,  
Bukireva str., 15, Perm, Russia, 614068  
isychev@interprogram.ru

***Il'ya I. Kheyfetz***

Perm State National Research University,  
Bukireva str., 15, Perm, Russia, 614068  
kheyfetz@psu.ru

***Olga L. Sokolova***

Perm State National Research University,  
Bukireva str., 15, Perm, Russia, 614068  
otoropova@interprogram.ru

In today's dynamic world, the problem of saving time resources becomes especially relevant. One of the promising approaches to solving this problem is the use of recommendation systems within various digital services and platforms. However, as the study shows, in existing systems for pre-ordering and delivery of goods, this problem still remains unresolved or is insufficiently solved [1-3]. This article discusses the types of modern recommendation systems, the possibility of using their algorithms and highlighting the main directions in designing the architecture of a system capable of integration into platform for pre-ordering goods and services.

**Keywords:** recommender systems, recommendation systems, neural networks, recurrent neural network, algorithms for recommender systems, multilayer perceptron, convolutional neural network, graph neural network.

## ОСОБЕННОСТИ ЭРГОНОМИКИ СИСТЕМ С ГЕНЕРАТИВНЫМ ИСКУССТВЕННЫМ ИНТЕЛЛЕКТОМ

*Щёголева Нелли Вадимовна, Сергеев Сергей Федорович*

Санкт-Петербургский государственный университет,  
199034, Россия, г. Санкт-Петербург, Университетская наб., 7-9,  
ssfpost@mail.ru

Рассматриваются вопросы учета человеческого фактора в дизайне систем с генеративным искусственным интеллектом. Эрготехнические системы, учитывающие психологические, социокультурные, коммуникативные и эргономические аспекты, демонстрируют преимущества по сравнению с традиционными техническими системами. Технологии генеративного искусственного интеллекта (ГИИ) позволяют создавать системы, повышающие удобство использования и соответствие коммуникации в человеко-машинной системе культурным и социальным контекстам.

**Ключевые слова:** генеративный искусственный интеллект, дизайн технических систем, эффективность, инженерная практика, человеческий фактор, эргономика.

**Введение.** Эргатические системы с высокой степенью автоматизации и адаптивности к пользователю, использующие информацию о рабочей среде, проникают во все сферы жизни, играя ключевую роль в обеспечении удобства, эффективности и безопасности человеческой деятельности [1]. Дизайн этих систем становится неотъемлемой частью инженерной практики, призванной обеспечить соответствие технологий потребностям и ожиданиям пользователей. В данном контексте концепция дизайна человеко-машинных систем с искусственным интеллектом приобретает особую важность, требуя глубокого понимания как технических, так и человеческих аспектов их функционирования [2]. Значительное внимание уделяется роли генеративного искусственного интеллекта (ГИИ) в дизайне симбиотической среды технических систем, который может использоваться для оптимизации процессов управления и автоматизации.

Взаимодействие между человеком и технологией становится все более тонким и интегрированным процессом, что выдвигает особые требования к психофизиологическим качествам пользователя. Эргатические системы с ИИ должны не только эффективно выполнять свои функции, но и учитывать особенности восприятия, поведения и предпочтений пользователей. В таблице 1 представлено сравнение основных факторов, влияющих на эффективность традиционных и с генеративным искусственным интеллектом эрготехнических систем и систем.

Таблица 1

**Факторы, влияющие на эффективность эргатических систем**

<b>Факторы</b>	<b>Классические эргатические системы</b>	<b>Эргатические системы с ГИИ</b>	<b>Комментарии</b>
<b>Психологические</b>	Высокая зависимость от психофизиологического состояния оператора	Снижение влияния психологических факторов благодаря автоматизации	ИИ уменьшает нагрузку и стресс за счет автоматизации рутинных задач и контроля оператора
<b>Физические</b>	Оператор активно задействован в алгоритмах управления и контроля, важна эргономика рабочей среды	Меньшее влияние, так как оператор меньше вовлечен в физические процессы	В системах с ИИ роль оператора в физическом взаимодействии снижается, но эргономика все еще важна
<b>Социокультурные</b>	Важно соответствие культурным нормам и ожиданиям оператора	Могут адаптироваться к различным культурным контекстам	Системы с ГИИ лучше адаптируются к культурным различиям, что повышает их эффективность
<b>Эргономические</b>	Ключевой фактор, влияет на скорость и точность работы оператора	Эргономика интерфейсов улучшена благодаря интеллектуальным системам	ИИ может улучшить удобство использования за счет интуитивных интерфейсов и персонализации
<b>Технические</b>	Ограниченная автоматизация, высокие требования к надежности	Высокая автоматизация, система может самостоятельно обнаруживать и исправлять ошибки	Системы с ИИ более устойчивы к техническим сбоям благодаря самообучению и самодиагностике
<b>Информационные</b>	Ограниченные возможности обработки данных, высокая зависимость от оператора	ИИ обеспечивает точный и быстрый анализ данных и принятие решений	Системы с ИИ способны более эффективно обрабатывать большие объемы данных и принимать оптимальные решения
<b>Организационные</b>	Высокая зависимость от распределения ролей и обязанностей	ИИ снижает потребность в четкой организации за счет автоматизации задач	ИИ может уменьшить нагрузку на организационную структуру, взяв на себя часть рутинных задач
<b>Когнитивные</b>	Важно внимание, память и обучаемость оператора, его сенсорные характеристики	ИИ снижает когнитивную нагрузку, предоставляя поддержку в принятии решений	ИИ может поддерживать эффективную коммуникацию в рамках текущего контекста
<b>Мотивационные</b>	Высокая зависимость от мотивации оператора, влияет на производительность	ИИ может поддерживать мотивацию оператора через персонализированные интерфейсы и обратную связь	В системах с ИИ мотивационные аспекты могут быть поддержаны через адаптивные системы взаимодействия и поощрения

Системы, в которых учитывается человеческий фактор, демонстрируют преимущества во всех рассматриваемых аспектах. Удобство использования, соответствие социокультурным контекстам, этическая и безопасная работа, а также способность к обучению и адаптации делают такие системы более эффективными и привлекательными для пользователей и свидетельствуют о симбиозе между человеком и машиной.

В эргономике человеческие факторы трактуются как интегральные характеристики связи человека и машины в системе «человек-машина-среда» (СЧМС), проявляющиеся в конкретных условиях их взаимодействия при функционировании системы, направленном на достижение заданных целей [3]. Человеческие факторы

– психофизиологические, психологические, социальные и коммуникативные качества, определяют качество и эффективность человеко-машинной связи.

Необходимо осознать влияние дизайна на восприятие и взаимодействие с техническими системами, особенно при использовании ГИИ. Дизайн играет решающую роль в создании удобных и интуитивно понятных, дружественных интерфейсов, которые могут значительно повысить эффективность работы пользователя, упростить процессы принятия решений, автоматизировать рутинные задачи и предоставлять ценные рекомендации на основе анализа данных [4]. Применение алгоритмов машинного обучения и нейронных сетей позволяет создавать персонализированные пользовательские интерфейсы, которые адаптируются к индивидуальным потребностям и предпочтениям каждого пользователя [5]. Кроме того, развитие дизайна технических систем с применением искусственного интеллекта открывает новые возможности для создания инновационных продуктов и услуг.

Понимание человеческой психологии играет ключевую роль в разработке технических систем с искусственным интеллектом. Эффективное восприятие и интерпретация информации является ключом к успешному использованию системы. В среде интерфейса пользователь должен легко интерпретировать и воспринимать предоставляемую информацию. Психологические исследования показывают, что внимание пользователя ограничено, и он склонен игнорировать информацию, которая, по его мнению, не является релевантной для текущих целей [6]. Важно минимизировать количество избыточной информации и обеспечить фокусировку внимания оператора на ключевых элементах интерфейса. Человеческая память также имеет ограниченный объем, поэтому важно предоставлять пользователю структурированную информацию таким образом, чтобы он мог легко ее запоминать, воспроизводить и интерпретировать при необходимости [1]. Использование ясных и легко запоминаемых метафор и ассоциаций может помочь улучшить запоминаемость элементов интерфейса. Важно учитывать эти и другие факторы при проектировании систем с искусственным интеллектом. Системы должны быть способны адаптироваться к индивидуальным предпочтениям и стилю мышления пользователя, чтобы обеспечить наилучший пользовательский опыт [7].

Психологические аспекты играют решающую роль в создании систем, которые не только эффективно выполняют свои функции, но и максимально удобны и интуитивно понятны для пользователей. Учет этих аспектов при проектировании интерфейсов и алгоритмов работы системы способствует улучшению взаимодействия между человеком и искусственным интеллектом.

Отметим, что в среде интерфейса эргатической системы с ГИИ целесообразно использование нового контура внутрисистемной коммуникации в виде диалога оператора со своим электронным ассистентом – помощником, реализованным на базе языковых генеративных моделей [1]. Возникают новые формы групповой работы в симбиотической паре «оператор-электронный ассистент» [7], что позволяет создавать интуитивно понятные интерфейсы, обеспечивать мультимодальный доступ к документации и ситуативным интерпретациям состояний системы, делает их более привлекательными для пользователей и способствует их широкому принятию и применению.



Особенности эргономики классических интерфейсов и с генеративным интеллектом представлены в табл. 2.

Таблица 2

### Эргономические аспекты классических и с ГИИ интерфейсов

Аспект	Классические интерфейсы	Интерфейсы с ГИИ
<b>Гибкость взаимодействия</b>	Фиксированные элементы управления и сценарии	Свободные формы общения, адаптация под пользователя
<b>Обучаемость и адаптивность</b>	Требуют обучения пользователя, интерфейс неизменен	Система обучается и адаптируется к пользователю
<b>Контекстуальность</b>	Ограничен текущим экраном или задачами	Учитывает широкий контекст и историю взаимодействий
<b>Точность управления</b>	Высокий контроль и предсказуемость	Возможны неоднозначные ответы, сложнее контролировать
<b>Человеко-ориентированность</b>	Структурированные задачи и процессы	Ориентированы на естественность и удобство пользователя
<b>Сложность реализации</b>	Простая архитектура, предсказуемое поведение	Сложная архитектура, интеграция продвинутых алгоритмов
<b>Обратная связь</b>	Предсказуемая, заранее запрограммированная	Разнообразная, основанная на контексте и данных

Развитие технологий искусственного интеллекта приводит к значительным изменениям формы взаимодействия человека с техническими системами. Одним из важных аспектов этого взаимодействия является естественное речевое и невербальное общение. Развитие голосовых интерфейсов и технологий распознавания речи позволяет пользователям общаться с ИИ более естественно и интуитивно. Это снижает порог вхождения для пользователей и повышает удобство использования. Помимо этого, чат-боты и виртуальные ассистенты позволяют пользователям получать информацию и выполнять задачи с помощью естественного языка, упрощая процесс взаимодействия.

Эффективное обучение и обратная связь также играют важную роль. Системы машинного обучения могут адаптироваться на основе данных о поведении и эффективности пользователя в системе управления, улучшая качество своих рекомендаций и предложений. Механизмы обратной связи позволяют пользователям выражать свое мнение о работе системы, предлагать улучшения и вносить свои предпочтения, что способствует постоянному совершенствованию сервиса и удовлетворению потребностей пользователей.

Не менее важными являются прозрачность и объяснимость системы. Создание систем ИИ, которые могут объяснять свои решения и действия, способствует установлению доверия и увеличению принятия системы со стороны пользователя. Кроме того, соблюдение принципов этики и прозрачности в обработке и использовании данных пользователей способствует созданию доверительных отношений и поддерживает позитивное взаимодействие с системой [8].

**Заключение.** Одним из наиболее важных аспектов интерфейсов с ГИИ является коммуникационное взаимодействие. Развитие голосовых интерфейсов и чат-ботов значительно улучшило способы общения пользователя с системами ИИ, делая этот процесс более естественным и интуитивным. Важной составляющей также является персонализация и контекстуальное взаимодействие в реальном времени. Алгоритмы машинного обучения позволяют системам ИИ адаптировать

свои рекомендации под индивидуальные предпочтения и ситуацию использования, что делает пользовательский опыт более глубоким, релевантным и эффективным. Однако для достижения такого уровня взаимодействия требуется эффективное обучение системы и постоянная обратная связь от пользователей.

Прозрачность и объяснимость системы являются неотъемлемыми компонентами успешного взаимодействия с человеком. Понимание принципов работы, логики и причин принимаемых решений улучшает доверие пользователей к системе и стимулирует к ее более эффективному использованию. Результаты исследования подчеркивают, что эффективное взаимодействие с человеком является критически важным фактором в разработке технических систем с искусственным интеллектом.

### Библиографический список

1. Сергеев С.Ф. Введение в когнитивную эргономику и инженерную психологию: учебное пособие. – Москва; Вологда: Инфра-Инженерия, 2024.
2. Сергеев С.Ф., Левин Д.Н. Основы эргодизайна внутрикабинных интерфейсов авиационных систем. Учебное пособие. – Москва; Санкт-Петербург, изд-во ВВМ, 2024. – 126 с.
3. Сергеев С.Ф. Методологические проблемы инженерной психологии и эргономики техногенного мира // Психологический журнал – 2022. – Том 43. – № 3. С. 25–33 [Электронный ресурс]. URL: <http://ras.jes.su/psy/s020595920020493-8-1> (дата обращения: 25.06.2022). DOI: 10.31857/S020595920020493-8
4. Сергеев С.Ф., Левин Д.Н., Игнатов А.Г. Искусственный интеллект в адаптивных внутрикабинных интерфейсах // Эргодизайн. – 2023. – № 4 (22). – С. 350–359. DOI: 10.30987/2658-4026-2023-4-350-359
5. Сергеев С.Ф. Психологические аспекты проблемы искусственного интеллекта // Институт психологии Российской академии наук. Организационная психология и психология труда. – 2020. – Т. 5. – № 4. – С. 33–53. DOI: 10.38098/ipran.opwp.2020.17.4.002
6. Сергеев А.В., Юсупова А.Ю., Сергеев С.Ф. Мультимерные интерфейсы в активной управляющей индуцированной виртуальной среде // Робототехника и техническая кибернетика. – 2022. – Том 10. – № 4. – С. 261–266. DOI: 10.31776/RTSJ.10403
7. Сергеев С.Ф. Интеллектуальный техносимбиоз в сложных человеко-машинных системах // Эргодизайн. – 2021. – № 1(11). – С. 70–76. – DOI: 10.30987/2658-4026-2021-1-70-76
8. Дубровский Д.И., Сергеев С.Ф. Проблема эргономической оценки эволюционирующих социотехнических систем с искусственным интеллектом // Эргодизайн. – 2022. – № 3(17). – С. 206–213. DOI: 10.30987/2658-4026-2022-3-206-213

### FEATURES OF ERGONOMIC SYSTEMS WITH GENERATIVE ARTIFICIAL INTELLIGENCE

*Nelly V. Shchyogoleva, Sergey F. Sergeev*

St. Petersburg State University,  
199034, Russia, St. Petersburg, Universitetskaya Emb., 7-9,  
ssfpost@mail.ru

This paper addresses the consideration of human factors in the design of systems with generative artificial intelligence. Ergotechnical systems that take into account psychological, sociocultural, communicative, and ergonomic aspects demonstrate advantages over traditional technical systems. Generative artificial intelligence (GAI) technologies allow the creation of systems that enhance usability and ensure that communication within human-machine systems aligns with cultural and social contexts.

**Keywords:** generative artificial intelligence, technical system design, efficiency, engineering practice, human factors, ergonomics.

## **ОПЫТ ПРИМЕНЕНИЯ БИБЛИОТЕКИ МАШИННОГО ЗРЕНИЯ ДЛЯ АНАЛИЗА ПОРОДНОГО СОСТАВА ЛЕСНЫХ НАСАЖДЕНИЙ НА ОСНОВЕ ДАННЫХ АЭРОФОТОСЪЕМКИ**

***Зотина Галина Витальевна***

Пермский государственный национальный исследовательский университет  
614068, Россия, г. Пермь, ул. Букирева, 15  
pastuhova13@yandex.ru

***Эстер Мария Вадимовна***

Общество с ограниченной ответственностью  
«Центр космических технологий и услуг»,  
614038, Россия, г. Пермь, ул. Лаврова, 14,  
estermaria.study@gmail.com

***Кедров Александр Владимирович***

Общество с ограниченной ответственностью  
«Центр космических технологий и услуг»,  
614038, Россия, г. Пермь, ул. Лаврова, 14,  
kedalex@gmail.com  
ekaterinazyankina@gmail.com

В данной работе представлена методика анализа породного состава лесных насаждений на основе данных аэрофотосъемки с использованием библиотеки машинного зрения YOLOv8. В ходе исследования были разработаны процессы подготовки данных, обучения модели и оценки ее эффективности. Эксперименты показали, что YOLOv8 обеспечивает высокую точность детектирования и классификации деревьев, превосходя традиционные методы. Несмотря на достигнутые успехи, модель демонстрирует трудности при классификации отдельных пород, что указывает на перспективы дальнейшего совершенствования.

**Ключевые слова:** YOLOv8, машинное зрение, аэрофотосъемка, анализ лесных насаждений, детектирование объектов, классификация деревьев.

**Введение.** Леса играют ключевую роль в глобальной экосистеме, предоставляя важные экологические услуги, такие как поглощение углерода, сохранение биоразнообразия и регулирование водного цикла. В условиях роста антропогенного воздействия и изменения климата возрастает необходимость точного мониторинга состояния лесных экосистем. Одним из главных индикаторов их здоровья является породный состав, изменения которого могут свидетельствовать о деградации или трансформации экосистемы [1, 3].

Традиционные методы анализа, включая полевые исследования, имеют ряд ограничений, таких как высокая трудоемкость, затраты времени и ресурсов, а также сложности с охватом больших территорий. В последние годы все большее внимание уделяется данным аэрофотосъемки (АФС), которые позволяют получать информацию о лесах с высоким пространственным разрешением.

В данном исследовании предлагается использование библиотеки YOLOv8 для анализа породного состава лесов на основе данных АФС. YOLOv8 – это со-

временная архитектура для детектирования объектов в реальном времени, сочетающая высокую скорость и точность. Этот подход снижает затраты на предобработку данных и повышает эффективность классификации, что особенно важно при работе с большими объемами данных [2, 4]. Цель исследования – разработка методики анализа породного состава лесных насаждений.

Существующие методы сталкиваются с несколькими проблемами. Во-первых, необходимо разрабатывать универсальные модели, которые смогут работать с данными, полученными с различных платформ [5, 6]. Во-вторых, методы машинного зрения требуют значительных вычислительных ресурсов и часто переобучаются на небольших выборках, что может приводить к нестабильным результатам на новых территориях. Эти ограничения указывают на необходимость создания более эффективных методов для анализа лесных насаждений на основе данных АФС.

Данные для исследования получены с помощью аэрофотосъемки (АФС) в Пермском крае. Использовались мультиспектральные изображения с высоким разрешением (до 10 см на пиксель), что позволило четко различать отдельные деревья. Ортофотопланы были разделены на изображения 640x640 пикселей, отобрано 275 квадратов для разметки. Эксперты аннотировали данные, указав породы деревьев, что обеспечило высокое качество разметки.

Для обучения модели были разделены на обучающую и тестовую выборки в соотношении 80:20. Проведена нормализация и аугментация данных (повороты, изменения яркости, контрастности, добавление шума), чтобы увеличить разнообразие обучающих изображений. Аннотации создавались с помощью CVAT, включая bounding boxes для каждого дерева. Всего было размечено шесть классов: береза (birch), осина (aspen), ель (spruce), пихта (fir), ива (willow), сухостой и мертвые деревья (dead).

Обучение проводилось на GPU-кластере с использованием предобученных весов. Модель обучалась на 300 эпох с mini-batch 16, что обеспечило баланс между эффективностью и точностью. Входное изображение – 640 пикселей. Применялся стохастический градиентный спуск с адаптивной скоростью обучения. Оценка проводилась на валидационной выборке, что позволило избежать переобучения и оптимизировать параметры модели. Гиперпараметры были настроены методом случайного поиска для достижения наилучших результатов.

График Precision-Recall (точность-полнота) демонстрирует взаимосвязь между точностью и полнотой модели классификации для различных классов. Классы "dead" и "spruce" показывают наилучшие результаты, достигая значений mAP (средняя точность) 0.950 и 0.860 соответственно, что указывает на высокую точность при сохранении полной полноты.




Рис. 1. График Precision-Recall (точность-полнота)




Рис. 2. График Precision-Confidence (точность-уверенность)

Средняя точность по всем классам составляет 0.671 при  $mAP@0.5$ , что свидетельствует о хорошем балансе между точностью и полнотой модели в целом. Классы "birch," "fir," и "aspen" демонстрируют умеренные значения  $mAP$ , в то время как "willow" имеет самую низкую  $mAP$  (0.209), что указывает на значительные проблемы в точности и полноте для этого класса. На графике Precision-Confidence представлена точность классификации модели для различных классов в зависимости от уровня уверенности. Классы "dead" и "spruce" достигают наивысшей точности, оставаясь близкими к значению 1 по всей шкале уверенности, что свидетельствует о высокой способности модели точно предсказывать эти классы. Средняя точность по всем классам достигает 1.0 при пороге уверенности 0.980, указывая на то, что при этом уровне уверенности мо-

дель делает исключительно правильные предсказания. Однако классы "birch," "aspen," и особенно "willow" демонстрируют гораздо более низкую точность, что указывает на необходимость улучшения модели для повышения точности предсказаний для этих классов, возможно, путем оптимизации признаков или баланса данных.

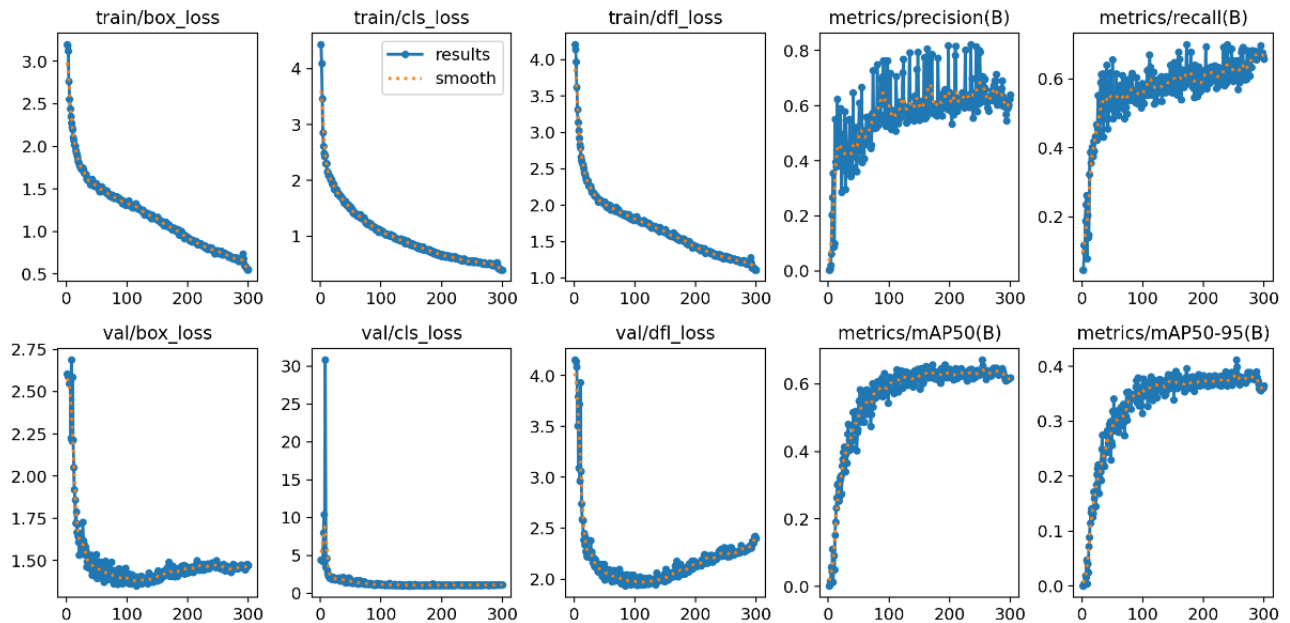


Рис. 3. Графики обучения (train) и валидации (val)

Графики отображают процесс обучения и валидации модели. В первой строке показаны метрики для обучения: убыток от координат bounding box (train/box\_loss), убыток от классификации (train/cls\_loss), убыток от dfl (train/dfl\_loss), точность (metrics/precision), полнота (metrics/recall) и среднее значение точности для IoU порогов от 0.5 до 0.95 (metrics/mAP50-95). Во второй строке аналогичные метрики представлены для валидации. По мере увеличения числа эпох наблюдается уменьшение убытков на тренировочных и валидационных данных, что свидетельствует о сходимости модели [7].

Для каждого тестового изображения модель выполняла детектирование объектов, после чего результаты детектирования сравнивались с эталонными данными, созданными экспертами. Основной целью тестирования было оценить, насколько точно модель может объединять деревья в кластеры (группы) и определять их породу. Результаты детектирования представлены ниже.



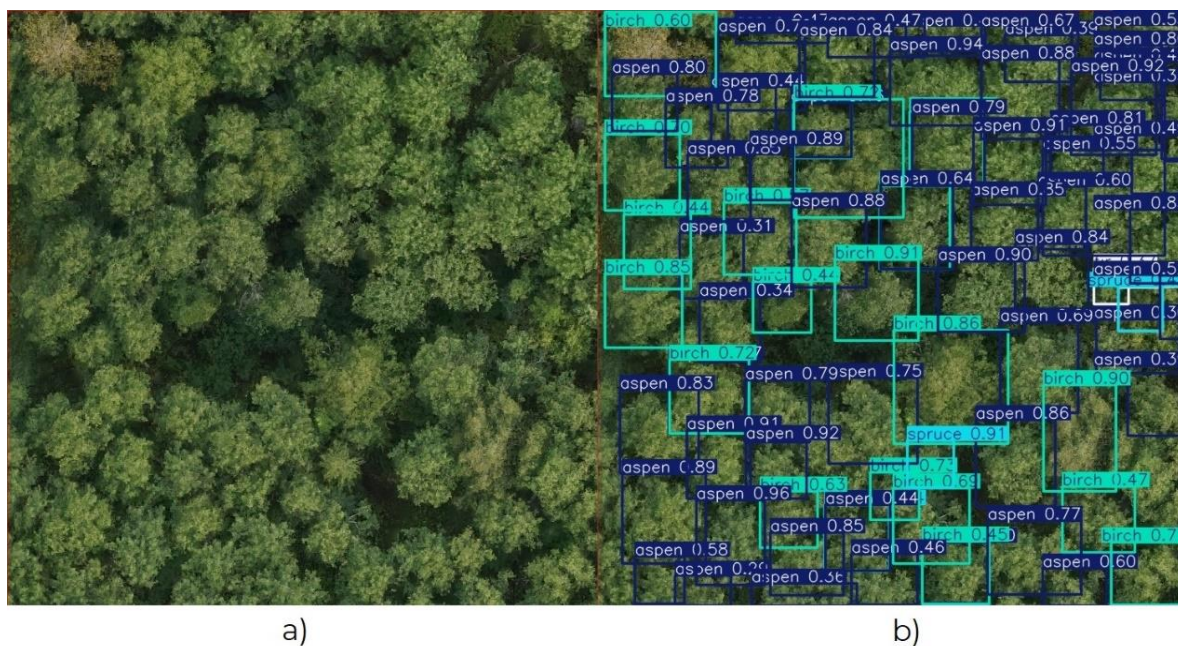


Рис. 4. Результаты определения пород по одно-тестовому изображению

Изображение а) отображает исходный фрагмент леса, в то время как изображение б) демонстрирует вывод модели, которая идентифицировала 81 дерево: 3 ели, 2 пихты, 20 берез и 56 осин. Проблема дифференциации между березами и осинами особенно заметна, что указывает на необходимость увеличения и улучшения обучающего датасета.

Данное распределение уверенности в классификации представлено на изображении с помощью меток, соответствующих предсказанным классам деревьев, и вероятностей.

Таким образом, постобработка результатов и их оценка показали, что предложенный метод с использованием YOLOv8 имеет высокий потенциал для применения в задачах мониторинга и анализа лесных насаждений, однако требует дальнейшей доработки для повышения точности и надежности в условиях реальной эксплуатации.

## Библиографический список

1. Smith J., Brown A., Green R. Using Random Forests and Support Vector Machines for Forest Species Classification Based on Remote Sensing Data // International Journal of Remote Sensing. 2019. Vol. 40, no. 3. P. 1241-1262.
2. Johnson P., Williams D., Martin L. Advanced Convolutional Neural Networks for Tree Species Identification Using UAV-Based Hyperspectral Imagery // Remote Sensing of Environment. 2020. Vol. 242. Article ID 111750.
3. Hansen M. C., et al. High-Resolution Global Maps of 21st-Century Forest Cover Change // Science. 2013. Vol. 342, no. 6160. P. 850-853.
4. Potapov P., et al. Annual Monitoring of Global Forest Cover with MODIS Data // Remote Sensing of Environment. 2017. Vol. 202. P. 117-132.
5. Goetz S. J., et al. Mapping and Monitoring Conifer Mortality Using Remote Sensing // Remote Sensing of Environment. 2003. Vol. 84, no. 1. P. 41-53.
6. Mohan M., et al. Monitoring Forest Health Using Hyperspectral Remote Sensing Data and Machine Learning Algorithms // International Journal of Applied Earth Observation and Geoinformation. 2017. Vol. 63. P. 153-162.
7. Redmon J., et al. You Only Look Once: Unified, Real-Time Object Detection // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 779-788.

# APPLICATION OF COMPUTER VISION LIBRARY FOR TREE SPECIES COMPOSITION ANALYSIS BASED ON AERIAL IMAGERY DATA

***Zotina Galina Vitalievna***

Perm State National Research University,  
15 Bukireva str., Perm, Russia, 614068  
pastuhova13@yandex.ru

***Esther Maria Vadimovna***

Limited Liability Company "Center for Space  
Technologies and Services",  
14 Lavrova str., Perm, 614038, Russia,  
estermaria.study@gmail.com

***Alexander Vladimirovich Kedrov***

Limited Liability Company "Center for Space  
Technologies and Services",  
14 Lavrova str., Perm, 614038, Russia,  
kedalex@gmail.com

This paper presents a methodology for analyzing tree species composition in forest stands using aerial imagery data and the YOLOv8 computer vision library. The study developed processes for data preparation, model training, and performance evaluation. Experiments showed that YOLOv8 provides high accuracy in detecting and classifying trees, outperforming traditional methods. Despite the achieved success, the model demonstrates difficulties in classifying certain tree species, indicating potential for further improvements.

**Keywords:** YOLOv8, computer vision, aerial imagery, forest stand analysis, object detection, tree classification.



## **ВИРТУАЛЬНЫЕ ИНСТРУМЕНТЫ В ИНТЕРФЕЙСАХ УПРАВЛЕНИЯ ПРОМЫШЛЕННЫМИ РОБОТАМИ**

***Сергеев Алексей Викторович,  
Плешаков Антон Олегович***

Центральный научно-исследовательский и опытно-конструкторский институт  
робототехники и технической кибернетики (ЦНИИ РТК),  
194064, Россия, Санкт-Петербург, Тихорецкий пр-т, д. 21  
etechnician@gmail.com, a.pleshakov@rtc.ru

***Сергеев Сергей Федорович***

Санкт-Петербургский политехнический университет Петра Великого,  
195251, Россия, Санкт-Петербург, Политехническая, 29  
ssfpost@mail.ru

В статье рассматриваются способы организации интерфейсов в индуцированной виртуальной реальности для управления роботами-манипуляторами. Предлагаемое решение апробировано на реальном роботе и включает в себя универсальный решатель обратной задачи кинематики и планировщик траектории, поддерживает работу в траекторном режиме.

**Ключевые слова:** промышленный робот, индуцированная виртуальная реальность, человеко-машинный интерфейс, управление роботами, ситуационная осведомлённость.

**Введение.** Эффективность взаимодействия человека и робота существенно повышается с появлением и распространением устройств виртуальной реальности. Расширяются возможности представления информации и способов обеспечения управляющих воздействий со стороны оператора. Однако, человек имеет физиологические ограничения пропускной способности перцептивной системы, которая позволяет ему оперировать не более чем  $7 \pm 2$  объектами («магическое» число Миллера) [1]. Всё что превышает данный объем оператором не воспринимается. По нашему опыту мы знаем, что представить конфигурацию манипулятора по данным углов поворота шарниров для человека является очень сложной задачей.

**Постановка задачи, классификация виртуальных инструментов интерфейсов в виртуальной среде.** Наиболее естественным для человека является восприятие трёхмерного пространства [2]. Для его построения предлагается использовать заранее известные 3D-модели объектов, а также индуцированные модели объектов, построенные системами технического зрения и генеративного искусственного интеллекта, которые на основании контента и датчиков обратной связи формируются, конфигурируются и расставляются по виртуальной сцене. Здесь же на сцене расположены виртуальные интерфейсы управления объектами и параметрами индуцированной среды (табл.).

**Классификация виртуальных инструментов в индуцированных средах**

Категория	Тип	Описание	Примеры
<b>Функциональное назначение</b>	Управление роботом	Инструменты для управления движениями робота и выполнения операций	Виртуальные джойстики, манипуляторы
	Мониторинг и визуализация	Инструменты для отображения данных и состояния системы	Индикаторы, графики, 3D модели элементов управления
	Диагностика и настройка	Инструменты для анализа и настройки параметров	Диагностические панели, панели настройки
	Обучение и симуляция	Инструменты для моделирования и обучения	Виртуальные симуляторы, обучающие модули
<b>Тип взаимодействия</b>	Графические	Визуальные элементы интерфейса	Кнопки, меню, иконки, графики
	Гаптические	Инструменты с тактильной обратной связью	Виртуальные джойстики с вибрацией
	Аудиальные	Звуковые сигналы и голосовые команды	Голосовые ассистенты, звуковые сигналы
	Комбинированные	Инструменты с несколькими типами взаимодействия	Виртуальные рукоятки с визуальным и звуковым откликом
<b>Уровень интеграции</b>	Основные	Базовые инструменты интерфейса	Основные элементы управления и мониторинга
	Вспомогательные	Дополнительные функции и информация	Инструменты для анализа и диагностики, подсказки
<b>Степень автоматизации</b>	Ручные	Полностью управляемые оператором	Прямое управление роботом через виртуальные панели
	Полуавтоматические	Частично автоматизированные инструменты с ИИ	Автоматическое выполнение задач с подтверждением
	Автоматические	Полностью автоматизированные инструменты с ИИ	Алгоритмы автопилота, автоматическая диагностика и построение инструментов и индуцированной среды

Таким образом оператор, не имея возможности присутствовать непосредственно в рабочей зоне может видеть непосредственно связанную с ней её виртуальную копию, которую он использует для принятия решений и управления, что позволяет оптимизировать процессы распределения психофизиологических ресурсов человека в процессе выполнения профессиональной деятельности. Такая виртуальная среда (индуцированная реальность) может содержать элементы, которые строятся не в виде копии реального мира, а являются дополненными к нему понятными для человека элементами и метафорой управления [3]. Например, можно использовать двумерный интерфейс в виде плоской поверхности, висящей в пространстве рядом с управляемым объектом. Большинству людей интуитивно понятно, как осуществлять взаимодействие с подобного рода интерфейсами.

**Экспериментальные и конструкторские работы.** В ЦНИИ РТК несколько лет ведется разработка и исследования человеко-машинных интерфейсов для управления робототехническими системами, посредством использования интерфейсов виртуальной реальности [4–7].

Архитектуру системы управления можно условно разделить на несколько частей: оператор, устройства виртуальной реальности, приложение Unity, ROS и физический робот. Сцена Unity содержит цифровую модель робота и объекты окружения, графический пользовательский интерфейс. Джойстики позволяют оператору взаимодействовать с графическим интерфейсом и объектами (маркерами и виртуальными инструментами) на рабочей сцене. Модель робота обновляется по пакетам ROS, которые постоянно циркулируют между Unity и ROS. ROS управляет движениями через контроллеры робота, в которые передаётся управление и возвращаются данные о текущем состоянии робота. Эти данные затем передаются в Unity, где используются для отображения текущего состояния робота на виртуальной сцене. Оператору кроме обычных двумерных интерфейсов доступны также и виртуальные инструменты, представляющие собой трёхмерные объекты на сцене, которые не имеют соответствующих аналогов в реальном мире.

В протестированной системе реализован режим копирующего управления, в котором нажатие курка оператором связывало заданное положение рабочего органа манипулятора с текущим положением руки оператора, все перемещения копировались в реальном времени. В виртуальном пространстве отображалось два манипулятора, один строился по данным от реального робота, а конфигурацию второго определял решатель обратной задачи кинематики исходя из заданного положения рабочего органа. Оператор может видеть одновременно движения реального робота и задаваемое им самим положение, к которому робот переходит по прямой линии от текущего положения.

Виртуальный интерфейс был протестирован на выборке из двенадцати испытуемых, имеющих различный опыт использования виртуальной реальности. Все участники успешно выполнили тестовое задание, а также высоко оценили простоту и интуитивность разработанного интерфейса управления.

**Заключение.** Для обеспечения быстрой, точной и безопасной работы управляемого оператором робота-манипулятора (эргатической робототехнической системы) необходимы пользовательские интерфейсы, обеспечивающие соответствие сложности решаемой задачи с возможностями оператора [8]. Интерфейсы в индуцированной виртуальной реальности позволяют компенсировать недостаток когнитивных и сенсомоторных возможностей оператора. В работе представлена удобная и интуитивно понятная система управления роботом.

## Библиографический список

1. Miller, George A. The magical number seven, plus or minus two: some limits on our capacity for processing information // *Psychological Review*. – Vol. 63 (2), Mar 1956. – P. 81-97.
2. Сергеев С.Ф. Обучающие и профессиональные иммерсивные среды. – М.: Народное образование, 2009. – 432 с.
3. Сергеев С.Ф. Эргономические проблемы проектирования интерфейса на базе индуцированных виртуальных сред // *Мир Авионики*. – 2006. – № 3. – С. 62–67.
4. Сергеев А.В., Сергеев С.Ф. Редукция сложности в интерфейсах робототехнических и эргатических систем // *Робототехника и техническая кибернетика*. – 2019. – Т. 7. – № 2. – С. 109–118. – DOI 10.31776/RTCJ.7204. – EDN WRLEPI
5. Сергеев А.В., Титов В.В., Шардыко И.В. Индуцированная виртуальная среда управления манипулятором, предназначенным для работы с радиоактивными материалами // *Робототехника и техническая кибернетика*. – 2021. – Т. 9. – № 1. – С. 32–41. – DOI 10.31776/RTCJ.9104. – EDN JFOOYE
6. Сергеев А.В., Юсупова А.Ю., Сергеев С.Ф. Мультимерные интерфейсы в активной управляющей индуцированной виртуальной среде // *Робототехника и техническая кибернетика*. – 2022. – Т. 10. – № 4. – С. 261–266. – DOI 10.31776/RTCJ.10403. – EDN KWMSGK
7. Сергеев С.Ф., Сергеев А.В. Опознание объектов с переменными признаками, движущихся в организованных группах в виртуальном 3D пространстве // Сборник тезисов XXIV съезда физиологического общества им. И.П. Павлова, Санкт-Петербург, 11–15 сентября 2023 года. – Санкт-Петербург: ООО «Издательство ВВМ», 2023. – С. 523. – EDN WDFGWR
8. Сергеев С.Ф. Введение в когнитивную эргономику и инженерную психологию: учебное пособие. – Москва; Вологда: Инфра-Инженерия, 2024.

## VIRTUAL TOOLS IN INDUSTRIAL ROBOT CONTROL INTERFACES

***Aleksey V. Sergeev, Anton O. Pleshakov***

Central Research and Development Institute of Robotics  
and Technical Cybernetics (RTC),  
194064, Russia, Saint Petersburg, Tikhoretsky Prospect, 21  
etechnician@gmail.com, a.pleshakov@rtc.ru

***Sergey F. Sergeev***

Peter the Great St. Petersburg Polytechnic University,  
195251, Russia, Saint Petersburg, Polytechnicheskaya St., 29  
ssfpost@mail.ru

The article discusses methods for organizing interfaces in induced virtual reality for controlling robotic manipulators. The proposed solution has been tested on a real robot and includes a universal inverse kinematics solver and a trajectory planner, supporting operation in trajectory mode.

**Keywords:** industrial robot, induced virtual reality, human-machine interface, robot control, situational awareness.

*Научное издание*

**Искусственный интеллект в решении  
актуальных социальных и экономических проблем XXI века**

Сборник статей по материалам Девятой всероссийской  
научно-практической конференции с международным участием

(г. Пермь, ПГНИУ, 17–18 октября 2024 г.)

**Часть 2**

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

Издается в авторской редакции  
Компьютерная вёрстка: *Л. Н. Ясницкий, М. А. Радионова*

---

Подписано в печать 10.12.2024. Формат 60×84/16.  
Усл. печ. л. 14,88. Тираж 100 экз. Заказ 148

---

Управление издательской деятельности  
Пермского государственного  
национального исследовательского университета.  
614068 г. Пермь, ул. Букирева, 15

Отпечатано в полиграфическом отделе  
614068 г. Пермь, ул. Букирева, 15  
Тел.: (342) 239-65-47

