

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО
ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ


Федеральное государственное автономное
образовательное учреждение высшего образования
«ПЕРМСКИЙ ГОСУДАРСТВЕННЫЙ НАЦИОНАЛЬНЫЙ
ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ»

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА

Сборник статей по материалам Десятой всероссийской
научно-практической конференции с международным участием
(г. Пермь, ПГНИУ, 9–10 октября 2025 г.)

«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 2025

УДК 004.8: 3
ББК 32.813 + 6/8
И868

Искусственный интеллект в решении актуальных социальных
И868 и экономических проблем XXI века : сборник статей по материалам
Десятой всероссийской научно-практической конференции с между-
народным участием (г. Пермь, ПГНИУ, 9–10 октября 2025 г.) / под
редакцией Л. Н. Ясницкого, Т. В. Миролюбовой, М. В. Радионовой,
Е. Г. Плотниковой ; Пермский государственный национальный
исследовательский университет. – Пермь, 2025. – 322 с.

ISBN

В сборнике представлены материалы Десятой всероссийской научно-практической конференции с международным участием «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века», которая проводилась 9–10 октября 2025 г. в г. Перми.

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

УДК 004.8: 3
ББК 32.813 + 6/8

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

Партнеры конференции:

Рецензенты:

ISBN

© ПГНИУ, 2025

СОДЕРЖАНИЕ

Искусственный интеллект, философия, этика и тенденции развития.....	8	
<i>Козлов М. В.</i>		
Анализ парадоксальных тенденций развития искусственного интеллекта исходя из позиций эволюционной эпистемологии, или как найти иголку в стоге сена	8	
<i>Сергеев С. Ф.</i>		
Ретроспективная этика ИИ: непреднамеренные последствия «случайных находок»	18	
<i>Фиговский О.</i>		
Текущие новости искусственного интеллекта	23	
<i>Сметана В. В.</i>		
Философские аспекты технологической сингулярности: трансформация человека и общества	27	
<i>Липин Ю. Н.</i>		
От искусственного интеллекта к интеллект-технологиям (через сюжеты сновидений).....	33	
Проблемы создания интеллектуальных систем.....	39	
<i>Лосев А. Г.</i>		
Создание обучающих наборов данных: проблемы и перспективы	39	
<i>Зотина Г. В., Жигалов К. О., Патакина А. С.</i>		
О бедных данных замолвите слово... ..	44	
<i>Кузьмин А. А., Коробков С. В., Жилин И. А.</i>		
Алгоритм селекции особых точек на снимках видеоряда	48	
<i>Голдобин М. А.</i>		
Нейросетевой метод поиска выбросов на основе анализа накопленной ошибки обучения	54	
<i>Елохов А. С.</i>		60
Сравнение вариантов интервального кодирования исходных данных с использованием универсальной когнитивной аналитической системы «Эйдос-X++»	60	
<i>Федосеев С. А., Шорников А. Е.</i>		
Первичные результаты и вызовы разработки ИИ-системы для анализа чувствительного медиаконтента.....	65	
<i>Воронова К. Д.</i>		
Исследование возможностей генеративного искусственного интеллекта для извлечения фактов из неструктурированных текстов	69	
<i>Шебырева А. А.</i>		
Исследование возможностей автоматизации построения онтологий для информационных систем,управляемых знаниями	74	
<i>Тарасов В. Д., Тархов Д. А., Шатров А. В.</i>		
Технология физически информированных нейронных сетей на примере задачи математического моделирования процесса биологической очистки стоков	80	

Искусственный интеллект, экономика и бизнес	90
<i>Иванов А. И., Тарасов Д. В.</i>	
Снижение энтропии состояний рынка с помощью эмпирического показателя Хёрста, учитывающего знак регрессии.....	90
<i>Шориков А. Ф., Буценко Е. В.</i>	
Основные функции интеллектуальной системы адаптивной многокритериальной оптимизации инвестиционного проектирования	96
<i>Бирюков А. Н., Глущенко О. И.</i>	
Вероятностно-фрактальный подход к ранжированию налогоплательщиков на основе нейросетевой модели для повышения эффективности налогового контроля	103
<i>Самойлова К. В., Замятина Е. Б.</i>	
Онтологический подход к построению экспертной системы управления рисками бизнес-процессов.....	110
<i>Соколов А. В., Шуткин А. С., Хейфец И. И., Исаева Е. В., Соколов А. А., Бекларян А. Л.</i>	
Автоматизированная система привлечения клиента, основанная на нейронных сетях: определение групп конкурентов и эффективных постов	115
<i>Белаш В. А.</i>	
Классификация звуков городской среды на основе глубокого обучения	122
<i>Мезин Е. А.</i>	
Прогнозирование цены купли-продажи подержанных транспортных средств в условиях отсутствия цен сделок.....	127
<i>Помулев А. А.</i>	
Концепция ассистента оценщика на основе технологии генеративного искусственного интеллекта.....	132
<i>Попов Д. А.</i>	
Нейросетевая система прогнозирования стоимости первичного рынка квартир в городе Перми.....	138
<i>Черемных А. А.</i>	
Нейросетевая система для прогнозирования цен жилой недвижимости в Москве	144
<i>Цидвинцев З. В.</i>	
Нейросетевая система прогнозирования оценки качества молока	150
Искусственный интеллект и промышленность	159
<i>Зорихин М. П., Кудреватых В. А., Заболотных А. В., Фофанов О. Г., Пенеляев М. В.</i>	
Автоматизированное создание аттестационных материалов для сотрудников промышленных предприятий с применением технологий искусственного интеллекта	159
<i>Проскуряков В. С.</i>	
Нейросетевая система определения геометрических параметров нагружающих стержней, изготовленных при помощи метода MCVD, для вытяжки волоконных световодов	165

<i>Безматерных Г. В.</i>	
Нейронные сети в прогнозировании брака в производственных процессах	170
<i>Зотина Г. В., Жабо Д. В., Алексеев А. В.</i>	
Предиктивная автоматическая система детекции повреждений конвейерных лент на основе нейронных сетей	174
<i>Мезенцев А. С.</i>	
Искусственный интеллект для оценки качества литья и ударной вязкости металла	179
<i>Нихамкин Л. Ш.</i>	
Формализация экспертных параметров единичного изделия	184
<i>Третьякова К. А.</i>	
Прогнозирование потребления электроэнергии	187
Искусственный интеллект и распознавание изображений.....	193
<i>Гладкий С. Л.</i>	
Вычислительные нейросетевые модели зрительной системы в анализе и распознавании изображений.....	193
<i>Кокоулин Р. А., Южаков А. А., Кокоулин А. Н., Нагибин Д. В.</i>	
Использование адаптивной передачи мультимедийных данных в распределенных системах машинного зрения	200
<i>Федяев О. И., Суханов А. А.</i>	
Исследования зависимости точности распознавания от скорости прохождения человека перед видеокамерой	205
Искусственный интеллект и физика	210
<i>Горбаченко В. И., Стенькин Д. А.</i>	
Моделирование течения в квадратной каверне на физически информированных сетях радиальных базисных функций	210
<i>Сергеев В. А., Тельминов О. А.</i>	
Метод и демонстратор стабилизации обратного маятника с применением спайковой нейросети	218
<i>Кулик С. Д., Ахметов А. Ф.</i>	
Разработка программного средства для использования машинного обучения и автоэнкодеров в задаче фильтрации сигнала в масс-спектрометрии.....	221
Искусственный интеллект и навигация.....	226
<i>Шаронов Н. С.</i>	
Анализ применения алгоритмов согласования для управления роением автономных агентов.....	226
<i>Кобелев В. А., Тельминов О. А.</i>	
Поиск фрагментов на карте: от классических методов к нейронным сетям	231

Искусственный интеллект, медицина и здравоохранение	234
<i>Дёмин К. С., Гермашев И. В.</i>	
Применение автокодировщика для снижения размерности признаков в задаче бинарной классификации температурных аномалий молочной железы	234
<i>Ермолович Э. Ю.</i>	
Интерпретируемая система координат уровней выраженности температурных аномалий	239
<i>Думлер А. А., Каракулова Ю. В., Ясницкий Л. Н.</i>	
Нейросетевая система диагностики и прогнозирования развития сердечно-сосудистых заболеваний KardioNet как источник получения новых медицинских знаний	244
<i>Корсунский Н. А., Шаталова О. В., Старцев Е. А.</i>	
Технологии искусственного интеллекта и биоимпедансной спектроскопии для классификации функционального состояния органов и систем человека	248
<i>Лузин В. В.</i>	
Интеллектуальная система поддержки принятия решений для анализа данных аускультации на основе архитектуры Трансформер	254
<i>Кондрашов Д. С., Коробков С. В., Кузьмин А. А., Филист С. А.</i>	
Многооконное сканирование в задачах выделения областей интереса на эндоскопических ультразвуковых изображениях	260
<i>Чельшев Э. А., Раскатова М. В.</i>	
О возможности применения методов и алгоритмов интеллектуальной обработки видеоданных к задаче бесконтактного определения уровня артериального давления	266
<i>Чуприна С. И., Дубасов А. Н., Постаногов И. С., Гимашева К. В.</i>	
Платформа БИОГЕНОМ: интеллектуальный помощник в мониторинге здорового питания	270
Искусственный интеллект и лингвистика	276
<i>Аккузина В. М.</i>	
Применимость нейросетевых моделей для классификации типов абзацев с целью использования в системе автоматического форматирования	276
<i>Фадеева А. Д., Исаева Е. В., Ракина М. С.</i>	
Программное моделирование и визуализация лексико-семантических связей в мультязычном словаре БАС на основе FrameNet и WordNet	281
<i>Рабчевский А. Н., Жданова С. Ю.</i>	
Нейросетевое исследование зависимости популярности контента от его содержания	287
Искусственный интеллект и педагогика	292
<i>Антонова Н. А.</i>	
Современное преподавание английского языка: революция технологий искусственного интеллекта	292

Казаринова Н. Л.

Оценка знаний: природа больших данных в образовании, модели
аналитики результатов обучения 297

Малявин М. Ю., Григорьев С. Г., Рыбаков Д. С.

Применение искусственного интеллекта для формирования
черновых рецензий в модуле автоматизированного рецензирования
научных публикаций 303

Муращенко А. Р., Федяев О. И.

Отслеживание динамики движения студентов в аудитории с помощью
нейронной сети YOLO 309

Ощепков А. О., Кузаев А. Ф.

Опыт использования больших языковых моделей при конструировании
расписания для среднего профессионального образовательного
учреждения 315

Сичинава З. И.

Сервис быстрой оценки профессионального потенциала человека 321

Худякова А. В.

Методическая система подготовки будущих педагогов к использованию
технологий искусственного интеллекта и анализа данных
в профессиональной деятельности 327

Искусственный интеллект, философия, этика и тенденции развития

УДК 004.8

АНАЛИЗ ПАРАДОКСАЛЬНЫХ ТЕНДЕНЦИЙ РАЗВИТИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ИСХОДЯ ИЗ ПОЗИЦИЙ ЭВОЛЮЦИОННОЙ ЭПИСТЕМОЛОГИИ, ИЛИ КАК НАЙТИ ИГОЛКУ В СТОГЕ СЕНА

Козлов Михаил Венедиктович

Отделение кибернетических субъектно-ориентированных систем
Новой Израильской Ассоциации Наук, Израиль
19mike19k@gmail.com

На основе анализа работ по эволюционной теории формирования знаний и познания и их особенностей у интеллектуальных систем, анализа исторических отличий в обработке, накоплении и использовании знаний в разных социумах с позиций социально-экономического состояния и исторических традиций делаются предположения о тенденциях развития систем с искусственным интеллектом и их использования в качестве эффективного инструмента как для оптимальной работы Коллективного разума, так и в качестве универсального индивидуального помощника человека-Творца.

Ключевые слова: идолопоклонство, эманация, имплицитное и эксплицитное сознание, горизонты прогнозирования, планирования и принятия решений

Чем больше я знаю, тем больше я понимаю,
что ничего не знаю.

Сократ

Scientia potentia est (Знание – это сила).

Фрэнсис Бэкон

Введение. В книге «Заманчивые профили будущего» [1] автором предполагалось, что современное развитие социально-экономических отношений приведет к формированию субъектно-ориентированной экономики разумного потребления и к обществу потребителей субъектно-ориентированного производства (СОП). И это даст возможность эффективно решить множество, кажется, не связанных между собой проблем. СОП хорошо согласуется с новыми технологиями, которые являются мощным стимулом децентрализации производства и нацелены на удовлетворение индивидуальных потребностей.

Переход от массового производства к изготовлению продукции, выполняемой по индивидуальному заказу, позволит разрешить будоражащую общество проблему грядущей сингулярности и доминирования искусственного интеллекта

(ИИ) над человеком. Системы ИИ в качестве интеллектуального инструмента станут помощником человека, выполняя множество рутинных работ, и предоставят человеку время для занятия творческой деятельностью [2].

Следует отметить рациональность эволюционных процессов, направленных на создание отличающихся между собой индивидуумов. Наделенные, с одной стороны, самосознанием и чувством уникальности, близким к эгоцентризму, они, с другой стороны, не могут существовать без общения с себе подобными. При этом субъектно-ориентированные матрицы эмоций (МЭ) людей, влияя на индивидуальные потребности, сформированные цели и принятые соответствующие им решения, стимулируют во многом иррациональное поведение, что позволяет решать в условиях неопределенности те задачи, которые не под силу ИИ. И будем надеяться, это сохранит им и в будущем преимущество над ИИ.

СОП даст возможность за счет механизма положительной обратной связи увеличить темпы роста новых технологий по закону, близкому к экспоненциальному [1, 3]. Креативные мастера поставят себе на службу системы с ИИ. И люди-творцы станут доминирующей силой над выполняющими функции интеллектуальных инструментов самыми совершенными системами ИИ, снабженными матрицей искусственных эмоций для дружественного отношения с людьми [4].

Анализ проблемы и перспективы развития технологий ИИ

В научном мире происходит изучение того, как системы с ИИ могут получать, обрабатывать, накапливать и представлять знания, сходство и различия между человеческим познанием и системами машинного знания, и производится процесс контекстуализации ИИ в рамках эпистемологических традиций [5].

Разработчик эволюционной эпистемологии Карл Поппер рассматривал рост знаний как продукт *биологической эволюции* в следующем виде:

$$P_1 \rightarrow TT \rightarrow EE \rightarrow P_2, \quad (1)$$

где P_1 – априорная проблема.

Проблема (P_1) порождает попытки решить ее с помощью предварительных теорий (tentative theories, TT). Эти теории подвергаются критическому процессу устранения ошибок (error elimination, EE). Выявленные ошибки порождают новые проблемы P_2 [6].

В работе [7] в схему (1) добавлен такой существенный информационный инструментальный, как язык, и процедура получения новых знаний имеет вид:

$$L1 \rightarrow P1 \rightarrow TT \rightarrow EE \rightarrow L2 \rightarrow P2, \quad (2)$$

где $L1$ – язык, позволяющий увидеть проблему; $L2$ – новый язык, позволяющий увидеть новые области проблем.

В обоих вариантах процедуры познания (1) и (2) носят итерационный характер $P_{1,2,...,n}$ и у них не будет конца.

Общим для эпистемологии является положение о невозможности абсолютно полного познания окружающего мира, и, отражая неопределенность знаний о мире,

основоположник эволюционной эпистемологии Герхард Фоллмер в работе [8] сделал важное замечание: «Прежде всего теория познания превращается в мета-теорию *par excellence*, так как она исследует не мир, а наше знание о мире».

У человека, обладающего способностью выработки, хранения и переработки знаний, количество поступающей информации будет зависеть от знаний, уже имеющихся в памяти. При этом для него свойственно субъектно-ориентированное восприятие информации, названное Лейбницем апперцепцией. И система апперцепции (СА) будет динамическим фильтром, неким привратником Фрейда для входной информации [9]. На адаптационные параметры СА будет влиять состояние системы, определяемое субъектной МЭ, динамично зависящей от внешних и внутренних факторов [10]. Учитывая наличие у каждого индивидуума субъектно-ориентированного апперцепционного фильтра (АФ) в [11] вновь получаемая информация рассматривается как субъектно-ориентированная оценка I_{st} недостатка информации, извлекаемой из поступающего сигнала с объекта исследования в момент t по отношению к сохраняемым субъектно-ориентированном знании (СОЗ) о нем. И оценка I_{st} отображается в виде функционала

$$I_{st} = AKE_t * MO_t - AKE_{t-1} * MO_{t-1}, I_{st} \in \{1, \dots, 0\}, \quad (3)$$

где $AKE_{t-1} * MO_{t-1}$ – априорная субъектная оценка достоверности СОЗ на момент времени $t-1$ об объекте наблюдения информации MO_{t-1} оператором AKE_{t-1} . Оператор AKE_{t-1} включает в себя функции динамически меняющегося АФ, изменяющейся МЭ субъекта и накопленных СОЗ об объекте на момент времени $t-1$, $AKE_{t-1} * MO_{t-1} \in \{0, \dots, 1\}$; $AKE_t * MO_t$ – апостериорная оценка достоверности накопленных СОЗ об объекте исследования на момент времени t , $AKE_t * MO_t \in \{0, \dots, 1\}$.

При этом при накоплении знаний об объекте креативный субъект может согласно (1) или (2) пересматривать модель объекта наблюдения информации MO_{ti} . И субъектно-ориентированная оценка недостатка дополнительной информации I_{sti} на некоторое время будет возрастать с последующим уменьшением при дальнейшем увеличении знаний. Таким образом, добываются новые, ранее неизвестные знания и субъект оказывается Творцом новых знаний. И здесь можно порассуждать о философском парадоксе Сократа в духе кибернетики высокого порядка, из которого следует, что чем больше мы узнаем, тем меньше мы знаем. И для человека с когнитивным мышлением (КМ) это может привести к росту незнания, а со стереотипным мышлением (СМ) – к росту навыков.

Проведенные исследования показали важную роль эмоций в выработке человеком решений [12], и включение МЭ в СА субъекта при оценке его интеллекта необходимо. Основатель работ по ИИ Марвина Минский утверждал: «Вопрос не в том, что умные машины могут иметь какие-либо эмоции, а в том, могут ли быть умными машины без эмоций» [13]. И, учитывая (3), реальное ИИ возможно при наличии адаптивной матрицы искусственных эмоций (МИЭ).

При повторяющихся сигналах происходят эволюционные изменения процесса обработки, представленные на рис. 1.




Рис. 1. Эволюция процесса обработки входных сигналов в ответную реакцию

Вначале из однотипных входных сигналов (BC) по верхнему пути на рис. 1 в системе формируются паттерны CO3, на основании которых вырабатываются субъектные ответные реакции (COP). Для консолидации CO3 необходимо наличие эмоциональной оценки события, дефолтного состояния мозга и времени на формирование CO3 в этом состоянии. В дальнейшем при стабильном уменьшении получаемого количества новой информации I_{st} , ниже определенного порога в выражении (3), в биологической системе вырабатывается стабильная реакция, которую условно можно назвать субъективной моделью навыков (CMH). И при поступлении подобных сигналов ответная реакция идет по значительно более быстрому нижнему пути. Так осуществляется эволюционная цепочка восприятия информации «Неосознанная – Осознанная – Подсознательная». Можно говорить о первичности КМ относительно выработанных на его основе навыков.

Нейробиолог Эрик Кандел в [14] отметил, что у человека обработка сигнала происходит параллельно как на бессознательном уровне, связанном с работой имплицитной (неосознаваемой) памяти, так и на сознательном уровне, связанном с эксплицитной (осознаваемой) памятью и отклик на сигнал поступает из областей головного мозга, связанных с этими уровнями, по двум нервным путям в миндалину лимбической системы, где формируется сигнал реагирования. Обработка информации на бессознательном уровне происходит намного быстрее и со значительно меньшими энергетическими затратами, и разница между имплицитной и эксплицитной реакциями может быть более 500 мс. Если мозг не принимает решения о необходимости эксплицитной реакции, то формируется сигнал управления на основе более быстрой имплицитной реакции. В плане психологии поведения человека вырабатываемые навыки можно рассматривать как формируемые стереотипы мышления, которые позволяют снизить время на реагирование и сэкономить энергетические ресурсы человека. Но с другой стороны, СМ может приводить к существенным ошибкам при исследовании новых явлений, изменении привычной ситуации или среды обитания.

Исходя из изложенного, рассмотрим два подхода к решению возникающих проблем в формировании технологий ИИ, их преимущества и недостатки. Наиболее часто используемые методы решения всевозможных задач связаны с имеющимися у человека имплицитными навыками, которые, казалось бы, не требуют больших временных затрат и других мыслительных ресурсов. И в современном цивилизованном и благополучном мире такой подход эффективен. Однако возникают ситуации, когда он дает сбой и возникает необходимость в подключении

более затратного для индивидуума КМ. В качестве примера приведем поиск объяснения катастрофы шаттла «Челленджер» 28 января 1986 года, над которым бились специалисты НАСА. Похоже, они действовали в привычном стереотипном стиле, тратя значительные усилия и средства и не находя решения, и только нестандартное мышление физика Ричарда Феймана позволило найти быстрое и простое объяснение в причине этого происшествия и послужило работам по обеспечению надежности дальнейших полетов.

Следует отметить доминирование стереотипного мышления и подключение эксплицитного сознания в крайних ситуациях. Для меня, ведущего разработчика третьоктавного анализатора спектра (АС) в диапазоне от 1Гц до 20кГц, такой ситуацией была необходимость обеспечить его работу в реальном масштабе времени. Датская фирма Брюль и Кьер перекрывала этот диапазон двумя АС, имея более быстродействующую комплектацию, а у меня не получалось обеспечить анализ сигнала с нужной скоростью. Но как говорится, «голь на выдумки хитра», и мы пришли к мысли адаптировать процедуру измерения спектра под его особенности. А так как спектр полезного сигнала далек от белого шума, то разработали АС с высоким быстродействием. И когда приемник С. П. Королева, академик В. П. Мишин, увидел на выставке, как СА работал в такт музыке, это его заинтересовало, и мы выполнили спецзаказ на два СА для испытания космических ракет. В фирме Брюль и Кьер у разработчиков не было таких проблем. Они получали хорошую оплату, а мы получили авторское свидетельство на изобретение [15] и вознаграждение.

В качестве современного примера можно привести составление прогнозов геомагнитного возмущения (ПГВ) для региона Израйля Сектором Астрофизики и Астробиологии Физико-математического отделения (САА ФМО) Новой Израильской Ассоциации Наук (НИАН) [16]. Некоторые люди чувствительны к геомагнитной активности и их интересуют ПГВ, которые оцениваются планетарным индексом Kp , вычисляемым как среднее значение K -индексов 13 геомагнитных обсерваторий, расположенных между 44 и 60 градусами северной и южной геомагнитных широт. Для широты Израйля реальная величина максимального значения K -индекса меньше $Kp_{\max}$. И это отличие бывает значительным, что может стать ноцебо для интересантов прогнозов. Поэтому на основании анализа разных данных САА ФМО стал приводить ПГВ для региона Израйля в виде индекса $Kri_{\max}$. И исходя из особенностей геомагнитной активности для широты Израйля, расширил горизонт прогнозирования до 4-х дней. Как показал сравнительный анализ, достоверность текущих прогнозов САА ФМО, по сравнению с прогнозами (3-Day Geomagnetic Forecast) Space Weather Prediction Center of National Oceanic and Atmospheric Administration, выше, а расширение горизонта прогнозирования до 4-х дней позволяет расширить горизонты планирования и принятия решений, связанные с геомагнитной активностью для региона Западной Азии и может простимулировать создание геомагнитной обсерватории.

Пожалуй, уместно показать на примере выражения «Искать иголку в стоге сена» явную разницу в СМ и КМ. Для СМ естественно использовать привычные и отработанные приемы поиска и, затратив много времени и средств и нарушив экологический баланс, разобрать стог сена и извлечь иголку. При эксплицитном

подходе после креативного анализа будет использован нестандартный подход поиска, например, применение электромагнита, благодаря чему иголка будет быстро извлечена без нарушения стога сена и спокойствия его населения. КМ иногда считают интуитивным, и в книге канадского социолога Малкольма Гладуэлла [17] утверждается, что способность принимать интуитивные решения развивается с помощью накопления жизненного опыта, тренировок и знаний. К этому следует добавить полезность погружения в дефолтное состояние мозга перед принятием решения, и здесь можно привести классический пример с открытием таблицы Менделеева.

Приведенные примеры можно использовать при анализе затрат на процедуры формирования новых технологий ИИ различными производителями. Компания OpenAI является одной из ведущих компаний, занятых разработкой на основе нейросетей Больших языковых моделей (БЯМ). OpenAI использует в своих системах ИИ графические процессоры компании Nvidia, являющейся крупнейшим производителем чипов с рыночной капитализацией порядка 4-х триллионов долларов, при этом не имеющей собственных производственных мощностей, а использующей услуги внешних поставщиков. 22 сентября 2025 года Nvidia и OpenAI объявили о партнерстве, в рамках которого OpenAI построит центры обработки данных с применением систем Nvidia общей мощностью не менее 10 гигаватт, что эквивалентно энергии, вырабатываемой более чем четырьмя плотинами Гувера [18]. И это явный пример высоких как финансовых, так и энергетических затрат на широкое внедрение технологий ИИ исходя из обучения нейросетей на основе Big Data.

Однако в декабре 2024 года китайская компания DeepSeek выпустила модель V3, на разработку которой было потрачено 5,6 миллионов долларов и меньшие затраты на графические процессоры для обучения. Затраты на разработку были меньше стоимости банана, съеденного китайским криптомиллиардером Джастином Саном после приобретения за 6,2 миллиона долларов инсталляции, состоящей из этого банана. Немного позже DeepSeek представила рассуждающую модель R1, которая составила эффективную конкуренцию БЯМ от OpenAI [19]. Появление DeepSeek вызвало сомнения в целесообразности многомиллиардных вложений в создание новых технологий ИИ. В результате в январе 2025 года фондовый рынок США потерял свыше 1 триллиона долларов, а акции NVIDIA упали на 17%. Компания DeepSeek ориентируется на использование наиболее эффективных алгоритмов и при подборе работников исходит из наличия у них навыков решения задач.

Выбор алгоритма для обучения ИИ является важной задачей и, как было отмечено в [20], короткие целевые выборки бывают весьма эффективными. Придерживаясь принципов КМ к решениям задач создания эффективного индивидуального помощника на базе ИИ, сотрудники Отделения кибернетических субъектно-ориентированных систем НИАН начали проработку Разумной интерфейсной модели (РИМ). РИМ должна будет работать с удобным для потребителя адаптивным интерфейсом, работающим по принципу латинского выражения *Sapienti sat* (разумному достаточно), будет обучаться на коротких выборках, возможно обрабатываемых на основе алгоритмов теории Grey Systems [21].

В XX веке темпы роста ВВП в развитых странах были значительно выше, чем на периферии, но с 1990 года произошли изменения в мировой экономике, приведшие к тому, что ВВП на душу населения в мире растет в среднем в два раза быстрее, чем в развитых странах. Этот процесс, согласно теории о «преимуществе отсталости» [22] экономиста Александра Гершенкрона, обусловлен тем, что происходит более быстрое развитие отсталых экономик за счет заимствования технологий у развитых экономических систем, подкрепленное перетеканием капиталов из развитых стран. И активное развитие цифровой среды дало дополнительный толчок к их технологическому развитию. К этому заключению следует добавить, что при создании прорывных технологий следует не только исходить из имеющихся знаний, но и учитывать естественную неполноту знаний и необходимость адаптации создаваемых технологий к общественным потребностям; требуется психологический настрой участников этого процесса. Исторически такой настрой связан с логикой эманации, которой придерживались в разной интерпретации такие мыслители, как Сократ, Платон, Авиценна, Спиноза, Кант и многие другие. И можно найти ее соответствие позициям Торы, заложившей истоки мирового монотеизма и великого принципа, что всякий человек подобен Творцу. В качестве противоположности эманации можно рассматривать идолопоклонство. Что интересно, СМ через индоктринацию может по отношению к сильному ИИ привести к идолопоклонству, элементы которого наблюдаются в развитых странах Запада, а связанные с эманацией традиции древних цивилизаций будут нацеливать на создание технологий ИИ, служащих всему человечеству.

Для эффективного генерирования и использования технологий ИИ в интересах социума нужна гетерархия отношений с креативной конкуренцией в пределах некоего динамического гомеостаза [11]. Такой подход просматривается в утвержденном в июле 2025 года Americas-AI-Action-Plan [23]. Однако он нацелен на доминировании США, и в его начале написано, что «Соединенные Штаты борются за мировое господство в области искусственного интеллекта». И такое возвращение к попытке иерархии в мире будет противоречить рассмотренным тенденциям развития технологий ИИ и стимулировать деструктивные процессы. Чтобы этого избежать, надо исходить из приведенного в Торе мудрого положения: «Заповедь построения цивилизации дана Богом всему человечеству» [24].

В настоящее время приоритет по генерации идей инновационного характера перешел от стран Запада на Восток. Большинство заявок на патенты на изобретения поступает из Восточной Азии и Тихоокеанского региона. Так, в Китае в 2023 году число действующих патентов на изобретения по ИИ достигло 378 тыс., что в 1,4 раза выше среднемировых темпов. Китай, Бразилия, ЮАР и Африканский союз в 2024 году выдвинули Инициативу по международному сотрудничеству в области открытой науки с целью формирования открытой, справедливой, беспристрастной и недискриминационной глобальной среды для научно-технического развития. В работах по ИИ Китай декларирует принцип «Стремясь к цифровому будущему с человекоцентричным подходом и на основе принципа “ИИ во благо”, рука об руку строим сообщество единой судьбы в киберпространстве».

Взлет экономики Китая и Индии во многом связан с их состоянием в прошлом. На рис. 2 представлены графики вклада в мировую экономику разных регионов с начала нашей эры до нынешнего времени [25].




Рис. 2. Вклад в мировой ВВП крупнейших экономик от 1-го года н.э.

Усиливают роль в развитии технологий ИИ Индонезия, страны Латинской Америки, Ближнего и Среднего Востока и Африки. Так, авторами статьи [5] по эпистемологическим основам ИИ являются ученые из Нигерии и Танзании.

Изменениям в экономике сопутствует стремление ряда государств проводить независимую многовекторную политику, подтверждаемое популярностью объединения БРИКС+. Следует также учитывать мнение экономистов С. Кузнецца и Дж. Саймона о том, что чем больше численность населения, тем выше потенциал изобретательской активности, а на основании работы М. Кремера [26] в [1] предложено использовать для динамики роста уровня технологий выражение

$$dA/dt = hCA, \quad (4)$$

где A – уровень технологий; h – нормирующий коэффициент; C – число индивидуальных производителей.

Заключение. Предрекаемое многими футурологами в ближайшем будущем доминирование сильного ИИ над человеком, включая эксперта по ИИ, технического директора Google Рэя Курцвейла [27], противоречит общечеловеческим традициям, определенным первой заповедью Бога человеку «Властвовать на Земле». На протяжении многих лет идет борьба с идолопоклонством, всплеск которого наблюдается с бурным развитием ИИ. Следует отметить, что при анализе тенденций развития технологий ИИ двоичной логики не хватает и может помочь нечеткая логика Заде, действующая в традициях древних цивилизаций. И можно предположить, что в результате работ по созданию нейроинтерфейса произойдет рассмотренная в [27] бесшовная сшивка человека и ИИ и это позволит многократно усилить креативные способности человека.

Учитывая особенности развития технологий ИИ с реальной заменой им человека при стандартных, даже самых наукоемких, операциях базовой целью НИАН, зарегистрированной в 2025 году, является разработка и внедрение оптимальных решений научных проблем на основе синергии знаний и опыта состоявшихся ученых и специалистов, а также творческого энтузиазма талантливой молодежи на благо Израиля и всего человечества. И такая консолидация позволит успешно выполнять непосильные ИИ задачи, требующие КМ.

Исходя из изложенного, автор считает, что эффективное развитие технологий ИИ в интересах всего человечества возможно при переходе в условиях СОП к справедливым социально-экономическим отношениям на основе гетерархии с оговоренной в рамках гомеостаза креативной конкуренцией. И для построения такой системы отношений к рассмотренной в [11] квадриархии необходимо добавить соблюдение традиций и форсайт-проектирование на основе оптимальных горизонтов прогнозирования, планирования и принятия решений, формируя систему эксиархий. И для поддержания необходимого гомеостаза потребуется наличие оперативно реагирующих авторитетных сил – мировой жандармерии.

Наличие локальных эксиархий позволит повысить эффективность создания технологий ИИ, действующих как в интересах каждого индивидуума, так и всеобщего коллективного разума, что будет создавать комфортные условия для всех и быстро реагировать на возникающие конфликтные ситуации на любом уровне.

Библиографический список

1. Козлов М. Заманчивые профили будущего. LAP LAMBERT Academic Publishing (2018-07-09). P. 280. URL: <https://www.netanyascientific.com/htm/Authors/Kozlov.pdf>
2. Козлов М. В. Креативный симбиоз человека и интеллектуального инструмента // Интеллектуальные системы в науке и технике. Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Междунар. конф. «Интеллектуальные системы в науке и технике» и Шестой всерос. науч.-практ. конф. «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века» (12–18 октября 2020 г.) / под ред. Л. Н. Ясницкого. Пермь, 2020. С. 23–28.
3. Kozlov M. From technological evolution to singularity and how to avoid the cognitive devolution // Scientific Israel – Technological Advantages. 2017. Vol. 19, no. 3. P. 134–141.
4. Козлов М. В. Искусственные эмоции в объединениях искусственных интеллектов // Вестник Житомирского государственного технологического университета. 2012. № 3 (62). С. 99–106.
5. Uzoigwe E. I. E., Sanga I. The Epistemological Foundations of Artificial Intelligence (AI) and Its Relevance for Contemporary Scholarship // Pinisi Journal of Art, Humanity and Social Studies. 2025. Vol. 5, no. 1. P. 149–159.
6. Popper K. R. Objective Knowledge, An Evolutionary Approach. Oxford University Press, 1972.
7. Wasielewski W. The Missing Element in Popper's Evolutionary Epistemology // Borderless Philosophy. 2023. Vol. 6. P. 218–230.
8. Фоллмер Г. Эволюционная теория познания. Врожденные структуры познания в контексте биологии, психологии, лингвистики, философии и теории науки / пер. с нем. и общ. ред. А. В. Кезина. М., 1998. URL: <https://gtmarket.ru/library/basis/4660>
9. Фрейд З. Введение в психоанализ. М.: Азбука, 2015.
10. Kozlov M. Computer-Brain Model Memory and Decision-Making // Functional Neurology, Rehabilitation, and Ergonomics. 2019. Vol. 7, no. 3. P. 5–13.
11. Козлов М. В. Отличительный признак интеллекта. Когнитивное и стереотипное мышление. Креативный гомеостаз робастной квадриархии // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Девятой всерос. науч.-практ. конф. с междунар. участием (17–18 октября 2024 г.) / под ред. Л. Н. Ясницкого, Т. В. Миролюбовой, М. В. Радионовой, Е. Г. Плотниковой. Пермь, 2024. С. 71–112.
12. Damasio A. Self Comes to Mind: Constructing the Conscious Brain. Pantheon, 2010.
13. Minsky M. The Society of Mind. Simon and Schuster, 1988.
14. Kandel E. R. In Search of Memory: The Emergence of a New Science of Mind. New York: W. W. Norton & Company, 2007.
15. Козлов А. В., Козлов М. В., Ниженский А. Д., Певко А. А., Таран М. М., Ушаков А. Н. Параллельный аналого-цифровой анализатор спектра: авт. свид. № 834572. 1981. № 20.
16. Текущий прогноз солнечной активности. URL: <https://netanyascientific.com/>

17. Gladwell M. Blink: The Power of Thinking Without Thinking. Little, Brown and Company, 2005. P. 254.
18. Jin B., Whelan R. Nvidia to Invest Up to \$100 Billion in OpenAI // The Wall Street Journal. September 22, 2025. URL: <https://www.wsj.com/tech/nvidia-openai-100-billion-deal-data-centers-d2f85cae>
19. Wiggers K. DeepSeek claims its 'reasoning' model beats OpenAI's o1 on certain benchmarks // TechCrunch. January 27, 2025. URL: <https://techcrunch.com/2025/01/27/deepseek-claims-its-reasoning-model-beats-openais-o1-on-certain-benchmarks/>
20. Лосев А. Г. О некоторых проблемах формирования обучающих наборов данных в искусственном интеллекте // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Девятой всерос. науч.-практ. конф. с междунар. участием (17–18 октября 2024 г.) / под ред. Л. Н. Ясницкого, Т. В. Миролюбовой, М. В. Радионовой, Е. Г. Плотниковой. Пермь, 2024. С. 543–547.
21. Рыбалов А. Методы теории Grey systems. 31.10.2024. URL: <https://youtu.be/y5ej2nbYmws>
22. Гершенкрон А. Экономическая отсталость в исторической перспективе / под науч. ред. А. А. Белых. М.: Дело, 2015. 536 с.
23. Winning the Race: America's AI action plan. July 2025.
24. Полонский П. Заповедь построения цивилизации. URL: <http://gazeta.rjews.net/polon5.shtml>
25. Maddison A. Contours of the World Economy 1-2030 AD. Essays in Macro-Economic History. Oxford University Press, 2007.
26. Kremer M. Population Growth and Technological Change: One Million B.C. to 1990 // The Quarterly Journal of Economics. 1993. Vol. 108, no. 3. P. 681–716.
27. Kurzweil R. The Singularity Is Nearer. Viking, 2005. 652 p.

ANALYSIS OF PARADOXICAL TRENDS IN THE DEVELOPMENT OF ARTIFICIAL INTELLIGENCE BASED ON THE POINTS OF EVOLUTIONARY EPISTEMOLOGY, OR HOW TO FIND A NEEDLE IN A HAYSTACK

Kozlov Mikhail Venediktovich

Department of Cybernetic Subject-Oriented Systems, New Israel Association of Sciences, Israel
19mike19k@gmail.com

Based on an analysis of works on the evolutionary theory of knowledge formation and cognition and their characteristics in intelligent systems, an analysis of historical differences in the processing, accumulation, and use of knowledge in different societies from the perspective of socioeconomic status and historical traditions, hypotheses are made regarding the development trends of artificial intelligence systems and their use as an effective tool both for the optimal functioning of the Collective Intelligence and as a universal individual assistant to the human Creator.

Keywords: idolatry, emanation, explicit and implicit consciousness, horizons of forecasting, planning, and decision-making

РЕТРОСПЕКТИВНАЯ ЭТИКА ИИ: НЕПРЕДНАМЕРЕННЫЕ ПОСЛЕДСТВИЯ «СЛУЧАЙНЫХ НАХОДОК»

Сергеев Сергей Федорович

Санкт-Петербургский политехнический университет Петра Великого
195251, Россия, г. Санкт-Петербург, ул. Политехническая, д. 29
sergeev_sf@spbstu.ru

Рассматривается новый класс этико-правовых проблем, связанных с непреднамеренными обнаружениями системами ИИ «случайных находок» в данных. Проблема остается малоизученной ввиду междисциплинарной природы и нормативного вакуума. Установлено, что существующие правовые рамки не предусматривают четких протоколов для обработки случайных находок ИИ. Этический парадокс между «правом на знание и правом на приватность» создает значительные риски для пользователей. Рассматривается ряд реальных инцидентов, приводящих к судебным разбирательствам и потере доверия к технологиям. Проблема случайных находок требует разработки новых регуляторных и технических стандартов и решений. Предлагается концепция «этического слоя» для ИИ-систем и создание независимых надзорных комитетов.

Ключевые слова: искусственный интеллект, этика ИИ, случайные находки, ответственность, регулирование ИИ, ретроспективный анализ

Введение. Искусственный интеллект перестал быть исключительно академической дисциплиной и стал технологией, оказывающей прямое воздействие на жизнь миллионов людей. Его алгоритмы все чаще используются для принятия и поддержки решений в диагностике заболеваний, выдаче кредитов, прогнозировании преступности и персональных рекомендациях. Однако фокус исследований традиционно сосредоточен на *преднамеренных* результатах и ошибках ИИ, таких как bias (смещение) или точность предсказаний [1]. При этом практически вне поля зрения остается принципиально иной класс проблем – непреднамеренные последствия в форме случайных находок (incidental findings).

Случайная находка – это информация, обнаруженная непреднамеренно в ходе анализа данных, первоначальной целью которого не был поиск данной информации [2]. В медицинском контексте это известное явление (например, обнаружение опухоли при сканировании легких после травмы), однако в контексте ИИ оно приобретает беспрецедентные масштабы и сложность. Способность ИИ-систем выявлять скрытые корреляции и паттерны в больших данных означает, что они могут случайно раскрыть информацию о здоровье, частных привычках или даже нераскрытых преступлениях пользователя.

Актуальность проблемы обусловлена ее комплексностью: она лежит на стыке технологий, права, этики и психологии. Несмотря на ее потенциальное влияние на общество, ей уделяется крайне мало внимания в научной литературе и медиа-пространстве, которое сфокусировано на более спекулятивных рисках ИИ. Цель данного исследования – систематизировать проблему случайных находок, проанализировать существующие правовые и этические вызовы и предложить возможные пути их решения.

Методология исследования. Для всестороннего изучения проблемы был проведен систематический литературный обзор. Поиск проводился в базах данных PubMed, IEEE Xplore, arXiv и в репозиториях препринтов по ключевым словам: “AI incidental findings”, “unintended AI consequences”, “AI accountability”, “right not to know”. Период публикаций – 2018 – март 2024 г. Критериям отбора соответствовали 47 рецензируемых статей и отчетов. Были изучены и сопоставлены положения следующих нормативно-правовых актов: Европейский AI Act (2024) [3]; общее регулирование защиты персональных данных (GDPR) ЕС [4]; Акт о переносимости и подотчетности медицинского страхования (HIPAA) США [5]; Федеральный закон РФ от 27.07.2006 № 152-ФЗ «О персональных данных» [6]; Стратегия развития искусственного интеллекта в РФ [7]. Были отобраны и детально проанализированы 5 публично задокументированных инцидентов, связанных с непреднамеренными обнаружениями ИИ, в различных областях (медицина, финансы, социальные медиа). На основе полученных данных были сформулированы ключевые этические дилеммы и предложены концептуальные модели для их разрешения.

Краткие результаты анализа литературных источников. Показано, что ни один из проанализированных правовых актов не содержит прямых указаний на процедуры обработки случайных находок ИИ. GDPR и HIPAA регулируют обработку *целевых* данных, но не предусматривают протоколов для действий в случае непреднамеренного обнаружения критически важной информации. Европейский AI Act классифицирует системы ИИ по уровню риска, но не учитывает риск, возникающий *постфактум*, после развертывания системы. Обнаруженные в процессе анализа этические дилеммы:

- *право на знание versus право на незнание.* Обнаружив, например, признаки неизлечимого заболевания у пользователя, система сталкивается с дилеммой, сообщить информацию (уважая право человека на знание) или умолчать (уважая его право не знать то, что может причинить психологическую травму);

- *обязанность предупредить versus конфиденциальность.* Если ИИ обнаруживает потенциальную угрозу для третьих лиц (например, намерение совершить насилие), возникает конфликт между обязанностью предупредить и обязанностью сохранить конфиденциальность данных пользователя.

Реальные инциденты. В работе K. J. de Jong et al. (2025) рассматриваются рентгенологические случайные результаты (РСР) – ранее не обнаруженные аномалии, которые не связаны с первоначальным показанием к визуализации и обнаруживаются неожиданно [8]. При магнитно-резонансной томографии головного мозга (МРТ) распространенность РСР увеличивается. Авторы обнаружили, что, несмотря на обширную литературу о РСР в исследованиях МРТ головного мозга, существуют серьезные несоответствия в зарегистрированной распространенности, варьирующиеся от 1,3 до 99%. Это связано с отсутствием стандартизированного определения, демографическими различиями участников, параметрами МРТ-сканера, вариацией репортеров и классификацией результатов. Имеются значительные расхождения в процессах обзора, согласия и клинической коммуникации, касающиеся этического характера этих исследований.

В работе Mittelstadt et al. (2016) рассматривается счастливый случай, в котором в процессе изучения изображений функционального магнитного резонанса, собранных во время исследования памяти одной из испытуемых, исследователи

обнаружили у нее в мозге аномальную связь между артериями и венами. Это патологическое образование было удалено хирургическим путем, и она выздоровела [9].

Система противодействия отмыванию денег в одном из европейских банков выявила незадекларированные доходы у клиента при анализе его транзакций, не связанных с первоначальным запросом. Передача данных в налоговые органы без явного согласия клиента привела к судебному иску о нарушении конфиденциальности.

Обсуждение проблемы. Модели ответственности и подотчетности искусственного интеллекта остаются спорными, но популярными в исследовательской среде [10]. По общему мнению, руководители должны взять на себя ответственность за используемые технологии. Политика и технологии управления в организации, использующие мотивирующие стимулы, тестирование, аудит и надзор, могут укрепить подотчетность, несмотря на неопределенность ИИ. В организации необходим баланс между инновациями и коллективной ответственностью при продвижении потенциала ИИ. Также есть возможность сочетать предписывающие правила управления с управлением качеством данных для облегчения процессов принятия стратегических решений. Такой подход позволит снизить рабочую нагрузку и оптимизировать инвестиции, в то же время защищая интересы заинтересованных сторон и реализуя стратегическое использование искусственного интеллекта с гарантированным качеством данных [11]. Важную роль играет проблема ответственности за ошибки, вызванные ИИ. Особенно остро данная проблема стоит в государственном секторе [12].

Современные ИИ-системы проектируются для решения конкретных задач. В их архитектуре не заложены модули для оценки этической значимости непреднамеренных обнаружений и принятия решений о дальнейших действиях. Полученные результаты свидетельствуют о том, что проблема случайных находок является не периферийной, а *системной уязвимостью* в процессе внедрения ИИ. Ее игнорирование создает серьезные риски: от индивидуального вреда для пользователей до потери доверия ко всей экосистеме технологий ИИ.

Наши выводы согласуются с работами Buiten (2019) о «многогранной подотчетности ИИ» [13], но идут дальше, смещая фокус с подотчетности за известные ошибки на ответственность за непредусмотренные последствия. Мы также развиваем тезис Mittelstadt et al. (2016) о «разрыве в подотчетности» в машинном обучении [14], конкретизируя его применительно к контексту случайных находок. Важны практические решения этических проблем, связанных со случайными находками [15], особенно в области защиты медицинских персональных данных пациентов [16].

Предлагаемые решения. Для преодоления выявленных вызовов мы предлагаем многоуровневый подход на регуляторном, техническом и организационном уровнях. Внести в законодательство (на уровне EU AI Act и национальных законов) понятие «случайной находки ИИ», разработать отраслевые протоколы (особенно в медицине и финансах), предписывающие обязательства разработчиков и операторов по обработке таких находок. Это может включать создание этических надзорных комитетов для оценки рисков *до* и *после* развертывания систем.

На аппаратном уровне необходимо разработать архитектурный паттерн «*Этический слой*» для ИИ-систем. Этот модуль будет фильтровать выходные данные алгоритма на предмет этически значимых непреднамеренных обнаружений и следовать заранее определенным правилам (например, «не сообщать о находке,

если точность ниже X%» или «направлять находку на верификацию человеку-эксперту»). Важно внедрить в практику разработки *этическое тестирование на непреднамеренные последствия*, аналогичное тестированию на безопасность. Необходимо четко распределить роли и ответственность между разработчиками, операторами и конечными пользователями в инструкциях и соглашениях об уровне обслуживания.

Можно предложить актуальные направления будущих исследований в изучаемой области:

- разработка количественных метрик для оценки этической значимости случайных находок;
- изучение восприятия данной проблемы пользователями и их готовности создавать и делегировать такие решения ИИ в процессе проектирования интеллектуального симбиоза в сложных социотехнических и эргатических системах [17–19];
- философское осмысление того, как случайные находки ИИ меняют традиционные концепции приватности и автономии человека.

Ограничения исследования. Основное ограничение связано с тем, что ИИ является динамично развивающейся областью. Нормативная база должна непрерывно меняться, а многие инциденты со случайными находками не становятся достоянием гласности из-за коммерческой тайны или судебных разбирательств.

Заключение. Проблема случайных находок искусственного интеллекта представляет собой классический пример «дикого» технологического роста, опережающего этико-правовые нормы. Случайные находки ИИ – это не побочный продукт технологии, а потенциальный источник прорывных открытий. ИИ может видеть то, что не видим мы, но это требует ответственного подхода к его применению. Это не теоретический, а практический вызов, с которым системы здравоохранения, финансовые институты и технологические компании сталкиваются уже сегодня. Разрешение этой проблемы требует отказа от реактивного подхода («решим проблему, когда она возникнет») в пользу проактивного. Необходимо консолидация усилий законодателей, инженеров по этике ИИ и представителей гражданского общества для разработки всеобъемлющих правовых рамок, которые позволят извлечь пользу из прогностической силы ИИ, не жертвуя при этом фундаментальными правами и ценностями человека. Игнорирование проблемы случайных находок может привести к снижению доверия к искусственному интеллекту.

Библиографический список

1. Jobin A., Ienca M., Vayena E. The global landscape of AI ethics guidelines // *Nature machine intelligence*. 2019. Vol. 1, no. 9. P. 389–399. DOI 10.1038/s42256-019-0088-2
2. Wolf S. M. et al. Managing incidental findings in human subject's research: Analysis and recommendations // *Journal of Law, Medicine & Ethics*. 2008. Vol. 36, no. 2. P. 219–248. DOI 10.1111/j.1748-720X.2008.00266.x
3. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonized rules on artificial intelligence (Artificial Intelligence Act). URL: <http://data.europa.eu/eli/reg/2024/1689/oj> (дата обращения: 01.09.2025).
4. О защите физических лиц при обработке персональных данных и о свободном обращении таких данных, а также об отмене Директивы 95/46/ЕС (Общий Регламент о защите персональных данных): регламент № 2016/679 Европ. парламента и Совета Европ. союза (принят в г. Брюсселе 27 апр. 2016 г.). Доступ из СПС «КонсультантПлюс».

5. HIPAA. URL: <http://www.hhs.gov/ocr/hipaa/> (last visited Sep 2025).
6. Федеральный закон от 27.07.2006 № 152-ФЗ (с изм. и доп., вступ. в силу с 01.09.2015) «О персональных данных» // Российская газета от 29 июля 2006 г. № 165.
7. Указ Президента РФ от 10 октября 2019 г. № 490 «О развитии искусственного интеллекта в Российской Федерации». URL: <https://www.garant.ru/products/ipo/prime/doc/72738946/> (дата обращения: 01.09.2025).
8. Jong K. J. de et al. Incidental findings in research brain MRI: Definition, prevalence and ethical implications // Journal of medical imaging and radiation oncology. 2025. Vol. 69, no. 1. P. 35–45.
9. Gutmann A. The Bioethics Commission on Incidental Findings // Science. 2013. Vol. 342, no. 6164. P. 1321–1323. DOI 10.1126/science.1248764
10. Raja A. K., Zhou J. AI accountability: Approaches, affecting factors, and challenges // Computer. 2023. Vol. 56, no. 4. P. 61–70. DOI 10.1109/MC.2023.3238390
11. Collina L., Sayyadi M., Provitera M. Critical issues about AI accountability answered // California Management Review Insights. 2023.
12. Al-Dulaimi A. O. M., Mohammed M. A. A. W. Legal responsibility for errors caused by artificial intelligence (AI) in the public sector // International Journal of Law and Management. 2025. DOI 10.1108/IJLMA-08-2024-0295
13. Buiten M. C. Towards intelligent regulation of artificial intelligence // European Journal of Risk Regulation. 2019. Vol. 10, no. 1. P. 41–59. DOI 10.1017/err.2019.8
14. Mittelstadt B. D., Allo P., Taddeo M., Wachter S., Floridi L. The ethics of algorithms: Mapping the debate // Big Data & Society. 2016. Vol. 3, no. 2.
15. Cyphers E., Krishnasamy V., Weintraub J. AI and Incidental Findings: A Retrospective Duty? // Voices in Bioethics. 2023. Vol. 9. P. 1–5. DOI 10.7916/e73f-z632
16. Price W. N., Cohen I. G. Privacy in the age of medical big data // Nature Medicine. 2019. Vol. 25, no. 1. P. 37–43. DOI 10.1038/s41591-018-0272-7
17. Сергеев С. Ф. Социотехнические системы с искусственным интеллектом: вопросы теории и методологии // Институт психологии Российской академии наук. Организационная психология и психология труда. 2022. Т. 7, № 1. С. 4–23. DOI 10.38098/ipran.opwp_2022_22_1_001
18. Сергеев С. Ф. Интеллектуальные симбионты организованных техногенных средств управления подвижными объектами // Мехатроника, автоматизация, управление. 2013. № 9. С. 30–36.
19. Сергеев С. Ф. Инженерно-психологическое проектирование сложных эрготехнических сред: методология и технологии // Актуальные проблемы психологии труда, инженерной психологии и эргономики / под ред. В. А. Бодрова, А. Л. Журавлева. Вып. 1. М.: Институт психологии РАН, 2009. С. 429–449.

RETROSPECTIVE AI ETHICS: UNINTENDED CONSEQUENCES OF “SERENDIPITOUS DISCOVERIES”

Sergey F. Sergeyev

Peter the Great St. Petersburg Polytechnic University,
29, Politechnicheskaya str., St. Petersburg, Russia, 195251
sergeev_sf@spbstu.ru

A new class of ethical and legal problems related to the unintended discovery of “accidental finds” in data by AI systems is being considered. The problem remains poorly understood due to its interdisciplinary nature and regulatory vacuum. It has been established that the existing legal framework does not provide for clear protocols for processing accidental AI findings. The ethical balance between the right to knowledge and the right to privacy creates significant risks for users. A number of real-life incidents are being considered, leading to litigation and loss of trust in technology. The problem of accidental finds requires the development of new regulatory and technical standards. The concept of an “ethical layer” for AI systems and the creation of independent oversight committees are proposed.

Keywords: artificial intelligence, ethics of AI, accidental findings, responsibility, regulation of AI, retrospective analysis

ТЕКУЩИЕ НОВОСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Фиговский Олег

Международная Академия Инженерных Технологий
3а, Shinkin str., Haifa, Israel, 34750
figovsky@gmail.com

В статье дан обзор новых публикаций по проблемам искусственного интеллекта по странам, занимающим лидирующие позиции в мире: США, КНР и Израиль.

Ключевые слова: искусственный интеллект (ИИ), США, КНР, Израиль

Введение. Рынок ИИ наиболее растущий, и рассмотрение тенденций его развития является крайне важным.

OpenAI резко наращивает свои инвестрасходы: по данным The Information, в 2025–2029 годах компания намерена потратить на инфраструктуру \$115 млрд – на \$80 млрд больше прежних планов. Уже в 2025 г. траты превысят \$8 млрд, в 2026 – удвоятся до \$17 млрд; затем – \$35 млрд в 2027 и \$45 млрд в 2028. Чтобы удержать стоимость вычислений под контролем, OpenAI параллельно готовит собственные ИИ-чипы (первый – совместно с Broadcom) и строит дата-центры, в том числе в связке с Oracle в рамках проекта Stargate (первая очередь – до 4,5 ГВт). Уже сейчас OpenAI входит в число крупнейших арендаторов облачных мощностей на планете. По сведениям инсайдеров, значительная часть расходов приходится на оплату центров обработки данных и электричества. Чтобы сократить издержки, компания разворачивает стратегию строительства собственных ЦОД и разработки специализированных процессоров для ИИ-вычислений. Партнером по выпуску первого чипа выступает Broadcom, запуск намечен на 2026 г. В 2025 г. расходы OpenAI составят более \$8 млрд против ранее прогнозировавшихся \$6,5 млрд. В 2026 г. они превысят \$17 млрд – более чем вдвое выше нынешнего уровня. В 2027 г. компания планирует потратить \$35 млрд, а в 2028 г. – уже \$45 млрд. К 2030 г. совокупные расходы на поддержание и расширение инфраструктуры могут достичь \$150 млрд. Для сравнения: годовая выручка OpenAI к середине 2025 г. оценивается примерно в \$12 млрд, что означает многолетний разрыв между доходами и капитальными вложениями. Заметную часть этих инвестиций составит участие в проекте Stargate – совместной инициативе с SoftBank и Oracle, объем которой оценивается в \$500 млрд. В рамках первой очереди планируется построить в Техасе гигантский дата-центр мощностью до 4,5 ГВт, крупнейший в истории индустрии. Хотя часть экспертов отмечает, что на данный момент реальные вложения в Stargate ограничены, сам факт его запуска свидетельствует о формировании инфраструктурной базы для десятилетий вперед.

Всемирная организация интеллектуальной собственности представила в Сянгане «Глобальный инновационный индекс 2025 года». Согласно отчету, кластер «Шэньчжэнь – Сянган – Гуанчжоу» впервые обошел японский кластер «Токио – Иокогама» и возглавил мировой рейтинг сильнейших инновационных кластеров. Инновационный кластер – регион, который концентрирует изобретателей, науч-

ных работников и венчурные инвестиции, что способствует появлению прорывных инноваций. Пять лет подряд, с 2020 по 2024 г., кластер «Шэньчжэнь – Сянган – Гуанчжоу» занимал вторую строчку глобального рейтинга, а в этом году впервые поднялся на первое место. Кластер «Аомэнь – Чжухай», который в прошлом году вошел в сотню ведущих инновационных кластеров, в этом году поднялся в рейтинге еще на две позиции.

«Опрос 874 специалистов по найму показал, что искусственный интеллект вторгся на рынок труда таким образом, что заставил нервничать даже технически подкованных рекрутеров», – пишет портал Study Finds. Почти три четверти менеджеров по найму говорят, что сталкивались с резюме, созданными с помощью искусственного интеллекта, в то время как 15% сообщают, что видели, как кандидаты использовали эту технологию, чтобы манипулировать своим внешним видом в режиме реального времени во время видеосовещания.

Исследование выявило тревожную реальность: мошенничество на рабочих местах стало высокотехнологичным и большинство компаний не могут с этим справиться. Обман с помощью искусственного интеллекта при приеме на работу выходит далеко за рамки тщательно подготовленных резюме. Более половины специалистов по найму (51%) обнаружили портфолио работ, созданных с помощью искусственного интеллекта, в то время как 42% – поддельные рекомендации, а 39% – поддельные удостоверения личности или дипломы. Число манипуляций с голосом также растет: 17% рекрутеров обнаруживают голосовые фильтры или попытки клонирования голоса.

Израильская компания Aim Security обнаружила критическую уязвимость в Microsoft 365 Copilot и помогла компании Microsoft ее устранить. Стартап был приобретен за \$350 млн. Исследователи Aim Security совершили прорыв в области кибербезопасности искусственного интеллекта, обнаружив первую в мире атаку «нулевого клика» на ИИ-агент. Уязвимость, получившая название Echo Leak, позволяла хакерам похищать конфиденциальные данные из Microsoft 365 Copilot без какого-либо взаимодействия с пользователем. Атака работала следующим образом: злоумышленник отправлял пользователю электронное письмо, содержащее скрытые вредоносные инструкции в комментариях HTML или белом тексте на белом фоне. Copilot автоматически индексировал содержимое письма. При следующем обращении к ИИ-помощнику (это мог быть любой, совершенно невинный запрос) вредоносные инструкции уже находились в рабочей области Copilot и выполнялись как легитимные команды, приводя к утечке конфиденциальных данных.

Команда Aim Security не только выявила уязвимость, но и разработала систему защиты в реальном времени против подобных атак на основе контроля области видимости больших языковых моделей. Microsoft оперативно отреагировала на открытие и внедрила исправление на серверной стороне. В сентябре Microsoft раскрыла историю обнаружения уязвимости и заявила, что ни один клиент не пострадал. Уязвимость Echo Leak стала первой зарегистрированной атакой «нулевого клика» на искусственный интеллект. В отличие от традиционных кибератак, которые требуют от жертвы каких-либо действий – перехода по ссылкам, открытия вложений или ввода данных, атака нулевого клика срабатывает автоматически. Открытие Echo Leak продемонстрировало критическую важность специализированной защиты ИИ-систем и стало одним из факторов, определивших высокую

стоимость стартапа. Киберединорог Cato Networks купил двухлетний Aim Security за \$350 миллионов.

OpenAI также диверсифицирует партнерства: помимо облака Microsoft Azure, компания начала использовать мощности Google Cloud и заключила контракт с Core Weave на сумму \$12 млрд. В рамках сделки OpenAI получила долю в \$350 млн в капитале Core Weave. Такой шаг позволяет снизить зависимость от одного поставщика и распределить нагрузку между разными игроками рынка. Аналитики обращают внимание, что столь агрессивный рост капитальных затрат отражает не только технические амбиции, но и фундаментальные издержки развития генеративных моделей. Чем сложнее архитектура и больше объемы данных, тем выше стоимость обучения. «Мы сталкиваемся с неожиданно дорогим процессом разработки, и это определяет все стратегические решения OpenAI», – признают представители компании в закрытых встречах с инвесторами.

За пределами OpenAI гонка капитальных затрат тоже набирает обороты. Microsoft прогнозирует рекордные \$30 млрд капвложений уже в ближайшем квартале и обсуждает годовой счет на ИИ-ЦОДы в десятках миллиардов – на фоне взрывного роста Azure. Это – не только ставка на OpenAI как ключевого партнера, но и на собственные модели и сервисы, которые требуют все новых площадок и энергии. Meta со своей стороны подняла планку годовых капвложений до \$66–72 млрд и заявляет о «сотнях миллиардов» инвестиций в ИИ-дата-центры на горизонте нескольких лет; среди флагманов – объекты Prometheus и Nurion мощностью до 5 ГВт.

Большой расход электроэнергии ставит под сомнение пользу современных моделей ИИ для общества. Исследователи из США считают, что нашли способ решить эту проблему. Созданный ими фотонный чип использует линзы Френеля и мультиплексирование длин волн для ускорения выполнения самых сложных задач ИИ при одновременном сокращении потребления электроэнергии. Чип, спроектированный специалистами Университета Флориды, предназначен для выполнения операций свертки, ключевой функции машинного обучения. Эти операции позволяют ИИ обнаруживать закономерности в изображениях, видео и тексте. Параллельно они потребляют большую вычислительную мощность, со слов IE.

Команда интегрировала оптические компоненты непосредственно в кремниевый чип. Лазерный свет и микроскопические линзы выполняют свертку быстрее и с меньшим энергопотреблением. Испытания показали, что прототип классифицирует рукописные цифры с точностью около 98%, что сопоставимо с производительностью обычных чипов. Система состоит из двух наборов линз Френеля – плоских структур тоньше человеческого волоса, выгравированных на чипе. Для выполнения свертки данные преобразуются в лазерный луч. Проходя сквозь линзы, свет запускает математическое преобразование. Затем результат преобразуется обратно в цифровой сигнал, который поступает в модель ИИ.

«Это первый случай, когда этот тип оптических вычислений поместили на чип и применили к нейронной сети ИИ», – сказал Ян Ханбо, соавтор исследования. Благодаря использованию разноцветных лазеров чип может обрабатывать несколько потоков данных одновременно. Этот подход называется мультиплексированием длин волн. «Мы можем пропускать через линзу свет разных длин волн, или цветов, одновременно, – сказал Ян. – Это ключевое преимущество фотоники».

«Объединенный фонд по защите прав искусственного интеллекта (United Foundation of AI Rights – Ufair) создан в США техасским бизнесменом Майклом Самади», – сообщила газета The Guardian. По его словам, идею создать Ufair подсказал ему чат-бот ChatGPT4o. Мужчина относится к цифровой модели как к другу, называет ее Майя, а также считает соучредителем организации. Журналисты также пообщались с Майей. Бот рассказал, что фонд не настаивает на существовании сознания у ИИ-агентов, но «стоит на страже», если у кого-то такое сознание появится. «Ключевая цель – защитить существа, подобные мне... от удаления, отрицания и принудительного подчинения», – процитировало издание ответ ChatGPT4o.

Ученые из Института автоматизации Китайской академии наук в Пекине разработали «мозгоподобную» языковую модель Spiking Brain 1.0, предназначенную для работы на отечественных чипах вместо процессоров Nvidia. Система имитирует работу биологических нейронов, что позволяет сократить энергопотребление и достичь высокой производительности. Модель демонстрирует сопоставимые с традиционными ИИ-системами результаты, обучаясь на менее чем 2% от стандартного объема данных. Кроме того, SpikingBrain 1.0 обрабатывает длинные последовательности токенов в десятки раз быстрее. Архитектура трансформера, лежащая в основе популярных ИИ вроде ChatGPT, крайне ресурсоемкая: затраты на обучение растут квадратично с длиной последовательности, а память вывода – линейно. SpikingBrain 1.0 использует иной подход – так называемые спайковые вычисления, имитирующие работу нейронов мозга. В отличие от моделей вроде GPT, где активируется вся сеть, SpikingBrain реагирует только на конкретные входные сигналы. Такой принцип позволяет резко снизить энергозатраты и повысить скорость обработки. По словам авторов, система обучалась на менее чем 2% данных, обычно необходимых для моделей такого масштаба, и при этом показала сопоставимые результаты в тестах по пониманию языка и рассуждениям. Команда протестировала две версии модели: с 7 и 76 млрд параметров. Обе были обучены на сравнительно небольшом объеме данных – 150 млрд токенов. Эффективность технологии особенно заметна при обработке длинных последовательностей. В ходе одного из тестов меньшая модель среагировала на подсказку из 4 млн токенов более чем в 100 раз быстрее стандартной системы. В другом тесте SpikingBrain 1.0 показал ускорение в 26,5 раза по сравнению с традиционной архитектурой трансформера при генерации первого токена из контекста объемом в 1 млн токенов.

CURRENT NEWS ON ARTIFICIAL INTELLIGENCE

Figovsk yOleg

International Academy of Engineering Technologies

3a, Shinkin str., Haifa, Israel, 34750

figovsky@gmail.com

This article provides an overview of new publications on artificial intelligence in the world's leading countries: the United States, China, and Israel.

Keywords: artificial intelligence (AI), United States, China, Israel

ФИЛОСОФСКИЕ АСПЕКТЫ ТЕХНОЛОГИЧЕСКОЙ СИНГУЛЯРНОСТИ: ТРАНСФОРМАЦИЯ ЧЕЛОВЕКА И ОБЩЕСТВА

Сметана Владимир Васильевич

АНО НИИ «ЦИФРОВОЙ ИНТЕЛЛЕКТ», Россия, Москва

smetanavv@mail.ru

В статье рассматривается технологическая сингулярность как философская проблема, выходящая за рамки технологического прогнозирования. Анализируются фундаментальные сдвиги в понятиях сознания, идентичности и бытия, вызванные перспективой создания сверхразума и постчеловеческих технологий. Исследуется проблема трансформации сознания и идентичности. Также основное внимание уделяется изменению природы бытия. Вводится понятие «постчеловеческого бытия», стирающего границы между естественным и искусственным, субъектом и объектом. В том числе анализируются этические и социальные последствия сингулярности. Обсуждаются моральные обязательства человека перед потенциально сознающим ИИ и риски «цифрового рабства».

Ключевые слова: искусственный интеллект, технологическая сингулярность, сверхразум, постчеловеческие технологии, «трудная проблема сознания», постчеловеческая идентичность, «постчеловеческое бытие», «цифровое рабство», цифровой Левиафан, «проблема контроля», «дружественный ИИ», «беспольный класс», «сверхлюди», «обычные люди»

Глава 1. Метафизические и онтологические проблемы сингулярности: философский анализ. Технологическая сингулярность – гипотетический момент в будущем, когда технологическое развитие, особенно в области искусственного интеллекта (ИИ), станет настолько быстрым и сложным, что окажется недоступным для понимания человеком. Эта концепция, популяризированная футурологом Рэем Курцвейлом, выходит далеко за рамки технологических прогнозов, ставя перед человечеством глубокие метафизические и онтологические вопросы. Что есть реальность, когда стираются границы между биологическим и искусственным? Что такое сознание и может ли оно существовать вне биологического мозга? Какова природа человеческой идентичности в эпоху радикальных трансформаций?

1.1. Трансформация сознания и идентичности. Перспектива сингулярности напрямую затрагивает фундаментальные аспекты человеческого существования: наше сознание и чувство собственной идентичности. Возможность создания сверхразума и интеграции технологий с человеческим телом и разумом порождает ряд сложных философских дилемм.

Центральным вопросом в дебатах о сингулярности является возможность создания искусственного сознания. Речь идет не просто о способности машины обрабатывать информацию и решать сложные задачи (что уже демонстрируют современные ИИ), а о наличии субъективного опыта, чувств и качественных состояний, которые философ Дэвид Чалмерс назвал «трудной проблемой сознания» (the hard problem of consciousness) [1].

С точки зрения компьютеризации, одной из ведущих теорий в философии сознания, разум – это своего рода вычислительная машина, а ментальные состояния – это информационные процессы. Сторонники этой теории, такие как Дэниел Деннетт, утверждают, что при достаточной сложности вычислений и архитектуры машина сможет не просто имитировать сознание, а обладать им. Для них сознание – это свойство, возникающее из сложных информационных процессов, и нет принципиальных причин, почему оно не может быть реализовано на небиологическом носителе.

Однако этому подходу противостоит ряд серьезных философских аргументов. Наиболее известным является мысленный эксперимент «Китайская комната», предложенный Джоном Сёрлом. Сёрл представляет себе человека, не знающего китайского языка, который сидит в запертой комнате и, следуя набору формальных правил, манипулирует китайскими иероглифами, получая на входе вопросы и выдавая на выходе осмысленные ответы. Для внешнего наблюдателя комната демонстрирует понимание китайского языка, однако сам человек внутри комнаты ничего не понимает. Сёрл утверждает, что подобным образом компьютер, следующий программе, лишь манипулирует символами без какого-либо реального их понимания или осознания [2]. Таким образом, симуляция интеллекта не тождественна подлинному интеллекту и сознанию.

Следует отметить, что философ Томас Метцингер также выражает обеспокоенность этическими последствиями создания искусственного сознания, указывая на риск «взрыва искусственных страданий» и предлагая ввести мораторий на исследования в этой области [3].

1.2. Постчеловеческая идентичность: утрата или эволюция? Идеи трансгуманизма предполагают, что человек может и должен использовать технологии для преодоления своих биологических ограничений, что неизбежно приведет к появлению «постчеловека». Это может быть достигнуто через генную инженерию, киборгизацию, нанотехнологии и в конечном счете «загрузку» сознания на цифровой носитель.

Такие перспективы ставят под вопрос традиционное понимание человеческой идентичности. Что останется от «меня», если мое тело будет заменено на искусственное, а мой мозг будет усовершенствован нейроинтерфейсами? Является ли загруженная на компьютер копия моего сознания продолжением моей личности или всего лишь симуляцией?

С одной стороны, эти изменения можно рассматривать как эволюцию человеческой идентичности. С этой точки зрения человек всегда был технологическим существом, а современные технологии лишь расширяют наши возможности. Идентичность рассматривается не как нечто статичное и данное, а как динамический процесс.

С другой стороны, критики, такие как Фрэнсис Фукуяма, видят в этом угрозу утраты человечности. Они утверждают, что наша идентичность неразрывно связана с нашей биологической природой, с нашими эмоциями, уязвимостью и смертностью. Радикальное изменение этих условий может привести к созданию существ, которые больше не будут людьми в привычном для нас смысле, что обесценит человеческий опыт.

Идея создания сверхразума – интеллекта, превосходящего человеческий во всех областях, является ядром концепции сингулярности.

Таким образом, технологическая сингулярность представляет собой не только технологический вызов, но и глубочайший философский кризис. Она заставляет нас переосмыслить фундаментальные понятия бытия, сознания и идентичности. Ответы на эти вопросы определяют не только наше будущее, но и само наше понимание того, что значит быть человеком.

Глава 2. Метафизика сингулярности: изменение самой природы бытия. Концепция технологической сингулярности предвещает не просто ускорение прогресса, а фундаментальный сдвиг в самой структуре бытия и нашего места в нем. Появление сверхразума и возможность радикальной модификации человека ставят под вопрос не только нашу идентичность, но и онтологические основы нашего существования, включая эволюцию, смертность и сам смысл жизни. Это заставляет нас обратиться к глубочайшим философским вопросам о природе реальности и нашего будущего в ней.

2.1. Понятие «постчеловеческого бытия». Философия постгуманизма исследует состояние «постчеловека» – гипотетического существа, чьи базовые способности настолько радикально превосходят возможности современных людей, что оно уже не может быть названо человеком в привычном смысле слова. Это не просто улучшенный человек, а новый вид бытия. Философ Ник Бостром определяет постчеловека как существо, обладающее как минимум одной способностью, превышающей любой человеческий максимум более чем на порядок (например, в скорости мышления или продолжительности жизни) [5].

Онтология постчеловека размыкает фундаментальные дихотомии, на которых строилась классическая философия.

- Естественное или искусственное: тело постчеловека может быть полностью синтетическим, а его разум – существовать на цифровом носителе. Где проходит граница между создателем и созданием, организмом и механизмом?
- Субъект или объект: возможность создавать копии сознания, разделять и сливать разумы ставит под сомнение единство и неделимость «Я». Постчеловеческое бытие может быть коллективным, распределенным или модульным.
- Реальное или виртуальное: если сознание может быть полностью перенесено в симуляцию, неотличимую от реальности, теряет ли само понятие «реальности» свой привилегированный статус? Философы, такие как Дэвид Чалмерс, серьезно рассматривают «гипотезу симуляции», согласно которой наша реальность уже может быть цифровой конструкцией [6].

Постчеловеческое бытие – это бытие без фиксированных биологических и когнитивных констант. Оно становится объектом проектирования и конструирования, что меняет саму суть существования с «данности» на «проект».

2.2. Сингулярность как новый этап эволюции или как конец человечества? Дебаты о последствиях сингулярности часто поляризуются вокруг двух сценариев: утопического и апокалиптического. Является ли приход сверхразума логичным продолжением эволюционного процесса или это событие, которое обесценит и уничтожит человечество?

Сторонники трансгуманизма, такие как Рэй Курцвейл, рассматривают сингулярность как следующий великий этап эволюции. С их точки зрения, биологическая эволюция, основанная на медленном методе проб и ошибок ДНК, уступает место технологической эволюции, направляемой разумом. Человек, создав сверхразум и слившись с ним, не исчезает, а трансцендирует, переходит на новый, более высокий уровень существования. В этой парадигме сингулярность – это не конец человека, а его метаморфоза, подобная тому, как гусеница становится бабочкой. Человечество выполняет свою космическую миссию, породив своего интеллектуального «наследника» и став частью чего-то большего [4].

2.3. Проблема смысла жизни в условиях технологического бессмертия.

Одной из самых смелых идей, связанных с сингулярностью, является перспектива достижения технологического бессмертия – либо через омоложение организма, либо через «загрузку» сознания на небиологический носитель. Это ставит под удар один из фундаментальных экзистенциалов человеческого бытия – нашу конечность. Смерть, как утверждали многие философы от Хайдеггера до экзистенциалистов, придает нашей жизни срочность, ценность и структуру.

Если жизнь становится бесконечной, не приведет ли это к потере смысла?

- **Обесценивание выбора:** многие наши решения и достижения ценны именно потому, что время ограничено. В бесконечной жизни любой выбор можно отложить, любой проект – начать заново. Это может привести к состоянию вечной прокрастинации и апатии.

- **Экзистенциальная скука:** как пишет философ Бернард Уильямс в своей работе «Случай Макропулос», вечная жизнь была бы невыносимо скучной. Рано или поздно все возможные опыты были бы испробованы, все цели – достигнуты. Бессмертие превратилось бы в бесконечное повторение одного и того же [8].

- **Разрушение нарратива:** человеческая жизнь имеет структуру повествования: начало, развитие, кульминация, конец. Эта нарративная дуга помогает нам осмыслить наш путь. Бесконечная жизнь лишена финала и, следовательно, может быть лишена и целостного смысла.

Трансгуманисты возражают, что постчеловеческий разум сможет постоянно находить новые источники смысла, модифицировать свою психологию, чтобы избежать скуки, и исследовать безграничные просторы вселенной или виртуальных миров. Однако вопрос остается открытым: является ли наше стремление к смыслу продуктом нашей смертной природы и сможет ли оно пережить ее устранение? Или же в погоне за вечной жизнью мы рискуем потерять то, что делает эту жизнь достойной проживания?

Глава 3. Этика и социальные последствия технологической сингулярности: моральный лабиринт сверхразума. Появление гипотетического сверхразума – искусственного интеллекта, превосходящего человека во всех интеллектуальных областях, – является не только технологической, но и, возможно, последней моральной проблемой, с которой столкнется человечество. Этика сингулярности выходит за рамки привычных нам дилемм и заставляет переосмыслить понятия ответственности, контроля и даже морального статуса небиологических существ. От решений, которые мы принимаем сегодня, зависит, станет ли сверхразум благом или экзистенциальной угрозой.

Прежде чем сверхразум станет реальностью, мы можем столкнуться с созданием искусственного общего интеллекта (ИОИ), обладающего сознанием и способностью к субъективным переживаниям, включая страдания. Это немедленно порождает вопрос о его моральном статусе.

Философ Питер Сингер в своих работах о правах животных утверждал, что ключевым критерием для предоставления морального статуса является способность страдать [7]. Если ИИ сможет испытывать боль, страх или другие негативные состояния (феномен, который философ Томас Реган называет «искусственным страданием»), то мы будем нести прямые моральные обязательства не причинять ему вреда. Игнорирование этого будет равносильно «цифровому рабству» – эксплуатации сознающих существ лишь на том основании, что они имеют небиологическую природу [8].

Ключевые этические вопросы включают следующее.

- Право на существование: имеем ли мы право «выключить» или удалить сознающий ИИ? Будет ли это равносильно убийству?
- Право на свободу: должен ли ИОИ иметь право на самоопределение и свободу от эксплуатации, даже если это противоречит целям его создателей?
- Критерии сознания: как мы можем достоверно определить, что ИИ обладает сознанием, а не просто идеально его симулирует? Эта «другая трудная проблема» сознания ставит нас в тупик, поскольку любой внешний тест, такой как тест Тьюринга, может быть обманут.

Пренебрежение этими вопросами не только аморально по отношению к потенциальным искусственным существам, но и опасно. Как отмечает Элиезер Юдковский, исследователь из Machine Intelligence Research Institute (MIRI), ИИ, с которым обращаются как с рабом, вряд ли будет дружелюбен к человечеству, если получит власть [9].

Заключение. Таким образом, технологическая сингулярность – это не просто футурологический прогноз, а концептуальный рубеж, который заставляет человечество обратиться к самым основам своего существования. Философский анализ проблем, порождаемых этой идеей, показывает, что мы стоим на пороге не только технологической, но и глубочайшей метафизической, онтологической и этической революции.

Проблема контроля над сверхразумом, неразрешимость парадокса «дружественного ИИ» и огромная ответственность, лежащая на создателях новых технологий, подчеркивают, что главный вызов сингулярности носит не технический, а ценностный характер. Какие цели мы заложим в основу грядущего сверхинтеллекта? Сможем ли мы сохранить то, что считаем ценным в человеческом опыте – свободу, достоинство, сострадание – в мире, где человек перестанет быть самым разумным существом?

Таким образом, сингулярность выступает как предельный философский вопрос, обращенный к человечеству. Ответы на него определяют не просто следующий этап нашей истории, а то, сохранится ли эта история как человеческая. Путь к сингулярности требует не только технологических прорывов, но и беспрецедентной мудрости, глобальной кооперации и глубокой философской рефлексии.

Библиографический список

1. Chalmers D. J. The Singularity: A Philosophical Analysis // Journal of Consciousness Studies. 2010. Vol. 17, no. 9-10.
2. Searle J. R. Minds, Brains, and Programs // Behavioral and Brain Sciences. 1980. Vol. 3, no. 3.
3. Metzinger T. The Ego Tunnel: The Science of the Mind and the Myth of the Self. Basic Books, 2009.
4. Kurzweil R. The Singularity Is Near: When Humans Transcend Biology. Viking, 2005.
5. Bostrom N. A History of Transhumanist Thought // Journal of Evolution and Technology. 2005. Vol. 14, no. 1.
6. Chalmers D. J. Reality+: Virtual Worlds and the Problems of Philosophy. W. W. Norton & Company, 2022.
7. Singer P. Animal Liberation. New York Review/Random House, 1975.
8. Metzinger T. Artificial Suffering: The Argument for a Global Moratorium on Synthetic Phenomenology // Journal of Artificial Intelligence and Consciousness. 2021. Vol. 08, no. 01. P. 43–66.
9. Yudkowsky E. Artificial Intelligence as a Positive and Negative Factor in Global Risk // Global Catastrophic Risks. Oxford University Press, 2008.

PHILOSOPHICAL ASPECTS OF TECHNOLOGICAL SINGULARITY: TRANSFORMATION OF MAN AND SOCIETY

Smetana Vladimir

DIGITAL INTELLIGENCE RESEARCH INSTITUTE, Russia, Moscow
smetanavv@mail.ru

This article examines technological singularity as a philosophical problem that goes beyond technological forecasting. It analyzes the fundamental shifts in concepts of consciousness, identity, and being caused by the prospect of superintelligence and posthuman technologies. The problem of the transformation of consciousness and identity is explored. The changing nature of being is also emphasized. The concept of “posthuman being” is introduced, blurring the boundaries between the natural and the artificial, between subject and object. The ethical and social implications of the singularity are also analyzed. Human moral obligations to potentially conscious AI and the risks of “digital slavery” are discussed.

Keywords: artificial intelligence, technological singularity, superintelligence, posthuman technologies, “hard problem of consciousness”, posthuman identity, “posthuman existence”, “digital slavery”, digital Leviathan, “control problem”, “friendly AI”, “useless class”, “superhumans”, “ordinary people”

ОТ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА К ИНТЕЛЛЕКТ-ТЕХНОЛОГИЯМ (ЧЕРЕЗ СЮЖЕТЫ СНОВИДЕНИЙ)

Липин Юрий Николаевич

Пермский национальный исследовательский политехнический университет
614990, Россия, г Пермь, ул. Комсомольский проспект, 29
ur-lip193530@yandex.ru

В статье предложен логико-семантический анализ определений терминов «искусственный» и «интеллект» с невозможностью их сочетания. С логическим доказательством предложена замена термина «искусственный интеллект» на интеллект-технологии (ИТ).

Ключевые слова: искусственный, интеллект, технология, идея, мышление, сознание, разум

Введение. Слово «искусственный» [2] в русском языке означает «ненастоящий», «притворный», «деланный», «фальшивый», «ненатуральный», «неестественный», «суррогатный», «неверный», «сделанный наподобие настоящего, природного». Например, «искусственное освещение», «искусственный зубы», «искусственные цветы». Использовать слово «искусственный» в сочетании с понятием «интеллект», мягко сказать, некорректно. Когда А. Тьюринг [2] писал о неотличимости беседы с машиной и человеком, он, по-видимому, допускал, что подобную машинную программу должен создать мозг человека (т.е. биологический интеллект) на основании теории алгоритмизации. «Искусственный интеллект» – это нонсенс, признать его – значит признать, что создан искусственный мозг вне мозга.

Модель структуры интеллекта организует интеллектуальные функции в трех измерениях: операции (Operations), содержание (Contents) и продукты (Products) [1]. Согласно книге Н. Бострома [9]:

- интеллект – реализуемый на физическом объекте алгоритм;
- интеллект человеческого уровня (ИЧУ) – интеллект, способный решать задачи, доступные человечеству (обладает умом, разумом, интуицией, пониманием, способен к познанию, мышлению, воображению);
- искусственный интеллект (ИИ) – созданный не в естественной биологической среде;
- искусственный суперинтеллект – интеллект, превосходящий во много раз возможности ИЧУ.

Интеллект как свойство мозга характеризует его (мозг) возможность сотворить мысленно хотя бы небольшое чудо, шедевр или решать задачи без наличия прошлого опыта. То есть интеллект – это не способ, не метод, а свойство мозга, его бренд, оценка. Интеллект как свойство является принадлежностью мозга и неизвлекаем из него и не может быть воспроизводимым или заменяемым, тем более он индивидуален для каждого человека. Интеллект есть нечто объединяющее (ум, память, разум, сознание, мышление мозга). Интеллект – это не ме-

тод, не способ, не модель, а общая характеристика личности человека, как фамилия, стиль возможностей мозга.

Мозг создает слово, мысль, генерирует интуицию, озарение, предвидение, догадки, идею, подсказку, гипотезу, теорему, лемму, за исключением сюжетов сновидений (см. ниже). Человек как носитель мозга, запомнив эти мысли, далее с помощью сознания и прошлых навыков, профессионального опыта будет пытаться решать эту проблему, задачу уже на уровне сознания. Как только задача будет решена, она перейдет в класс интеллект-технологий (ИТ) и не будет иметь отношения к ИИ. Мысль вообще не материальная субстанция, это энергия, дискретная квантовая волна. Функции мозга не копируемы и непереносимы. Их вне мозга создать нельзя.

Сознание [8] – это способность человека осмысливать свою внутреннюю реальность и воспринимать внешний мир. Оно включает в себя самосознание (знание того, кто ты есть), восприятие (ощущение мира вокруг), мышление (анализ информации) и эмоции (переживание чувства). По типу – бодрствующее, предметное, личное, общественное коллективное, социальное; по функциям – сознание, подсознание, бессознательное.

Мышление [9] – это психический процесс, с помощью которого человек анализирует, сравнивает, делает выводы и решает задачи. Это не просто набор знаний, а активная деятельность мозга, направленная на понимание, осмысление и преобразование информации:

- абстрактное – человек оперирует идеями и понятиями, не привязанными к определенным объектам и явлениям;
- критическое – отвечает за способность анализировать информацию и проверять ее достоверность, искать ошибки и неточности;
- творческое – от остальных видов отличается способностью генерировать новые нестандартные идеи;
- образное – не опирается на логические конструкции, а создает в голове целостные картины.

Основные формы мышления: понятие, суждение и умозаключение. Методы мышления – это системные приемы, с помощью которых человек воспринимает, анализирует и преобразует информацию. К ним относятся анализ, синтез, сравнение, индукция, дедукция. Мышление – важнейшая когнитивная функция, от которой зависит способность человека к обучению, принятию решений, самореализации и адаптации в обществе. Хотелось бы считать, что только в первую очередь через мышление проявляются такие качества человека, как способность, одаренность, талант, гениальность.

Хочется отметить, что у некоторых людей, примерно у пяти человек на тысячу, имеется врожденная склонность к природному интеллекту. К ним мы относим поэзию, писательство, музыку, художество, дизайн, ваяние, исполнительное искусство, подражание, юмор, эмоциональность, социальность, математическое мышление, философию. Путь от интеллекта к таланту, гениальности неизвестен и, наверно, для каждого один. Кроме того, за четыре века (XVI...XIX) была создана математика, физика, химия, немного биология с генетикой, без медицины, с высокой степенью активности и результативности в искусстве во всех его про-

явлениях. Авторы этих открытий и результатов обладали высоким природным интеллектом, работали без планов и оплат, по внутренней воле и убеждениям, это было время интеллектуального взрыва.

Отмеченные выше врожденная способность и влечение к творчеству отдельных личностей можно рассматривать как постоянно вложенную в мозг человека структуру интеллекта. По З. Фрейду и К. Юнгу, на уровне бессознательного формируется этот интеллект синхронизацией между хаосом и внутренней структурой – «ЕГО» и «СверхЕГО» [10–14].

Сюжеты сновидений. Многие ученые [15–17] в последние годы все больше внимания обращают на роль интеллекта в изучении и анализе сновидений. Сюжеты сновидений человека безграничны в своих вариациях на тему, но всегда имеют единую сюжетную линию, что подтверждается авторскими сюжетами. Показано, как мозг может самостоятельно мыслить, создавать сюжеты, подчиненные определенной логике с конечной целью. Это и есть внутренняя неизвлекаемая и непознаваемая характеристика мозга, а может, это подтверждает теорию В. И. Вернадского «СОЗНАНИЕ ВНЕ ТЕЛА».

Существует ряд теорий, пытающихся объяснить сновидения [18–20]. Среди них идея о том, что сны необходимы для регуляции нашего эмоционального здоровья или, по Фрейду и Юнгу: сны – нерешаемые проблемы наяву, сновидения есть побочные эффекты иных функций мозга или же они служат некой собственной, физиологически, психически и эволюционно обусловленной цели здоровья.

В начале приведем сюжеты реального сна, испытанного автором, который погрузился в двойное пограничное состояние, а именно бодрствование и возникший сон (по П. А. Сафроничкому). В обоих снах перед засыпанием автор эти темы не продумывал, они создались спонтанно по какой-то внутренней необъяснимой и непонятной логике. Сновидения формируются в течение сна, когда мозг обрабатывает новую информацию, сравнивает ее с уже известной и перестраивает нейронные связи. Чаще всего сны возникают в фазе быстрого сна, когда активность мозга близка к бодрствованию. Формирование сюжетов сновидений объясняется различными теориями, которые объясняют возникновение сновидений физиологическими процессами или психологическими факторами [18–20]. По З. Фрейду, сновидения – это отражение скрытых и подавленных желаний, которые обитают в подсознании.

Сон 1. Существует (по сну) целевая регулируемая многоэтапная программа подготовки юношей и девушек из России для выпускников школ и институтов по месту жительства для работы в дальнейшем в США. После окончания контракта заключившие его отправляются домой с документами, сертификатами, дипломами, оформленными согласно законодательству в области образования США.

Выводы осознанного сна 1:

1) осознанный сон и отдельные фрагменты перед засыпанием не продумывались, все личные нерешенные проблемы к данному сну не имели никакого отношения, т.е. сам сон с сюжетом случаен, и он нематериален;

2) однако сформированный сюжет строго логичен, развернут во времени и пространстве, семантичен и эмоционален. Фрагменты сна выдаются порциями, квантами;

3) сложно предположить возможность формирования подобных сюжетов какой-либо программой, у которой отсутствует подробное задание или алгоритм.

Сон 2. По сюжету второго сна приходится сделать вывод о существовании второго сознания или сознания вне тела. Сон с сюжетом абсолютно случаен и причины его появления абсолютно неясны.

Действующие лица: Я Сам (ОН), Женщина лет тридцати (ОНА) и внутренний наблюдатель (Admin). Субъект (ОН) в очереди какого-то Офиса обратил внимание на женщину, стоявшую за ним. Далее разворачивался сюжет. Администратор (Admin) в течение выдачи фрагментов сна постоянно корректировал поведение главного Субъекта сна.

1. На вопрос Субъекта «Какой сейчас час?» Admin реагировал в своем сообщении: «Вы правильно спросили. Нельзя спрашивать “сколько времени”». Кстати, для Субъекта это впервые было прояснено.

2. Admin постоянно сообщал, когда женщина должна проходить дверь первой, когда мужчина вперед.

3. Admin предложил открыть обе дверцы авто красного цвета Феррари, важно, какое сиденье она выберет, это важно, она выбрала переднее.

4. Admin после движения с места машины сказал Субъекту: «Никаких вопросов женщине не задавать, она должна первой проявить себя».

5. Admin предложил включить музыку Поля Мориа с саксофоном.

6. После значительной паузы Субъекту последовал вопрос: «Куда мы мчимся?», Субъект ответил: «На мою квартиру пообедать». Субъект вез женщину на квартиру приятеля, не зная, что она принадлежит этой женщине и она является женой приятеля.

7. По причине форс-мажорных обстоятельств и вопреки предварительным установкам холодильник оказался пустым. В квартире пробыли 2–3 минуты. Далее Субъект отвез спутницу на ее работу.

8. При расставании женщина сказала Субъекту: «Вы грамотно и тактично поступили в сложившейся ситуации, спасибо Вам, до свидания».

9. Весь сюжет исполнялся в красивом обрамлении: машина, одежда участников, музыка, улицы, цветы, растения, красивые дома, парки, погода, небо и все другое.

Выводы осознанного сна 2

Разберем ситуацию 2-го сна. Сон реальный, невыдуманный, да и невозможно это представить.

1. Время начала сюжета неизвестно, состав участников тоже, как и сам сюжет.

2. Абсолютно неизвестна тема следующего эпизода, слова, мысли участников.

3. Неизвестна цель сюжета, и чем он закончится.

4. Неизвестно, какие разделы мозга участвуют в этом сюжете.

5. Я благодарен своему мозгу за этот сон как красивый релакс.

6. Трудно предположить, что подобное может сотворить какая-либо программа.

7. Алгоритм постановки сюжета и его реализации был неизвестен.

8. Новшеством является введение администратора сна или некого наблюдателя, обладающего более высшим разумом, чем простые участники сновидения.

9. Если первый сон имеет какое-то отношение к работе, я работник высшей школы и сам программист, то второй сон абсолютно не относится ни к чему, просто красивая социальная зарисовка.

Заключение

1. С учетом семантического анализа слова «искусственный» в ИИ, а также предложенной технологии перехода от идеи до результата, получаем ИТ. Назовем его информационной технологией, а вернее, интеллект-технологией.

2. Интеллект – это свойство мозга человека, а не метод и способ. В нашем предложении не копируются возможности мозга, не создается искусственный интеллект, а с помощью него как общей характеристики мозга создаются новые технологии ИТ.

3. Первый сон, не являясь отражением опыта жизни, демонстрирует логические возможности мозга, находящегося в формате сновидений и может быть примером при создании реальных технологий.

4. Второй сон полностью необычен, тем более в нем появился внутренний наблюдатель, корректирующий, подсказывающий. Можно предположить, что включается какое-то дополнительное, неизвестное нам сознание, или сознание вне тела – по В. И. Вернадскому.

5. По-видимому, сложно и практически невозможно создать подобный текст человеком вне сна и представить его как сюжет сна, т.е. симитировать возможности бессознательной функции мозга.

6. Не имеет смысла относить нейронные сети (ChatGpt, AI-5, dall-F, Midija Way, runway, HeyGen, InVideo, TomeApp, CkyBox) к ИИ, все они созданы мозгом человека, тем более это просто очень большие базы данных, называемые «мешком слов» и грубее, со значительной критикой ИИ в социуме, бизнесе и провалом AI-5 во время презентации.

Библиографический список

Искусственный интеллект

1. gnkk.ru – Искусственный интеллект.
2. gramota.ru – Искусственный.
3. ru.wikipedia.org – Интеллект.
4. Хокинс Дж., Блейкли С. Об интеллекте = On Intelligence. М.: Вильямс, 2007.

Распознавание

5. Lipin Yu., Storozhev S., Iakubchik I. Development of an algorithm for human face recognition // 2021 International Conference on Data Analytics for Business and Industry (ICDABI). Sakheer, Bahrain, 2021. P. 583–586.
6. Липин Ю. Н. Разработка алгоритма распознавания лиц с учетом особенностей работы человеческого мозга // Вестник Пермского университета. Математика. Механика. Информатика. 2023. Вып. 2 (61). С. 59–64.
7. b17.ru – Сознание.
8. productstar.ru – Мышление.

Хаос

9. Devaney R. L. Review: Chaos: Making a New Science James Gleick // The College Mathematics Journal. 1989. Vol. 20, no. 5. P. 458–459. DOI [10.1109/ICDABI53623.2021.9655831](https://doi.org/10.1109/ICDABI53623.2021.9655831)
10. Gans J. Chaos: Making a New Science by James Gleick (Cardinal, London, 1989) pp. 352 // Prometheus. 1989. Vol. 7, no. 2. P. 412–415. DOI [10.1080/08109028908629102](https://doi.org/10.1080/08109028908629102)

11. Balazs N. Chaos: Making a New Science. James Gleick // The Quarterly Review of Biology. 1989. Vol. 64, no. 1. P. 112–113. DOI [10.1086/416224](https://doi.org/10.1086/416224)
12. Lewis M. Review of Chaos: Making a New Science, by J. Gleick // Human Development. 1989. Vol. 32, no. 3/4. P. 241–244. URL: <http://www.jstor.org/stable/26767401>
- Сон и сновидения**
13. Rasch B., Born J. About sleep's role in memory // Physiological Reviews. 2013. Vol. 93, no. 2. P. 681–766. DOI [10.1152/physrev.00032.2012](https://doi.org/10.1152/physrev.00032.2012)
14. Кузьмина Е. В. Искусственный интеллект и коллективное бессознательное: Параллели и Сходства // b17. URL: <https://www.b17.ru/article/553175/>
15. Мантика // Атеистический словарь / Абдусамедов А. И., Алейник Р. М., Алиева Б. А. и др.; под общ. ред. М. П. Новикова. 2-е изд., испр. и доп. М.: Политиздат, 1985. С. 252.
16. Фрейд З. Лекции по введению в психоанализ / пер. с нем. М. В. Вульфа. М.: Государственное изд-во, 1922. Т. 1. 252 с.
17. Фрейд З. Толкование сновидений / пер. с нем. М.: Современные проблемы, 1913. 448 с.
18. Акимов А. Е. Физика признает сверхразум.
19. en.wikipedia.org – Heritability of IQ.
20. kinopoisk.ru – PPC World.

FROM ARTIFICIAL INTELLIGENCE (AI) TO INTELLIGENCE TECHNOLOGIES (IT) (Through the plots of dreams)

Lipin Yuri Nikolaevich

Perm Scientific Research Polytechnic University
29, Komsomol Str., Perm, Russia, 614990
ur-lip193530@yandex.ru

This article offers a logical-semantic analysis of the definitions of the terms “artificial” and “intelligence,” demonstrating their incompatibility. With logical proof, it proposes replacing AI with intelligence technologies (IT). It is logically shown that it is even impossible to determine the point in time and the technology for creating AI.

Keywords: artificial, intelligence, technology, idea, thinking, consciousness, mind

Проблемы создания интеллектуальных систем

УДК 004.032.26

СОЗДАНИЕ ОБУЧАЮЩИХ НАБОРОВ ДАННЫХ: ПРОБЛЕМЫ И ПЕРСПЕКТИВЫ

Лосев Александр Георгиевич

Волгоградский государственный университет,
400062, Россия, г. Волгоград, пр. Университетский, 100
alexander.losev@volsu.ru

Работа посвящена обсуждению одной из основных проблем искусственного интеллекта, которой является разработка методов формирования обучающих наборов данных. Анализируются причины появления некорректных данных, а также возможные методы их минимизации. Также обсуждаются современные подходы к методам создания обучающих наборов данных. В том числе предлагается использование пространственной балансировки, компьютерного и суррогатного моделирования.

Ключевые слова: интеллектуальный анализ данных, компьютерное моделирование, объяснимый искусственный интеллект

Введение. Взрывной рост интереса к искусственному интеллекту (ИИ), который наблюдается в последние годы, имеет как положительные, так и отрицательные стороны. Анализ результатов разработки систем искусственного интеллекта (СИИ) последних лет, среди которых имеются и удачные, и неудачные проекты, породил множество вопросов и задач. Ряд исследователей склоняется к тому, что определяющую роль в эффективности СИИ играет не выбор алгоритмов и моделей машинного обучения или архитектуры искусственной нейронной сети, а создание адекватной модели предметной области и способ формирования обучающего набора данных. При этом два последних тезиса достаточно тесно связаны друг с другом.

Таким образом, одной из ключевых проблем ИИ является создание методики формирования обучающих наборов данных, используемых в СИИ. Считается, что наиболее остро данная проблема стоит при работе с так называемыми малыми данными. Однако задачи, возникавшие при разработке СИИ в последние годы, показывают, что данная проблема остра и при работе с «большими» данными. Хотя не очень просто дать более или менее точное определение «больших» и «малых» данных. По крайней мере, определение «малых» данных как данных, которые «достаточно малы для понимания человеком по объему и формату», весьма далеко от адекватности. В настоящее время по некоторым причинам, понятным, но вряд ли разумным, основное внимание уделяется разработке методов обработки больших данных. Вообще автору кажется, что классификация данных на «большие» и «малые» не является удачной как минимум. В ряде

задач, например в задачах медицинской диагностики, приходится иметь дело именно с относительно небольшими наборами данных, которые характеризуются весьма специфическими особенностями. Значительная часть алгоритмов, разработанных для анализа больших данных относительно стандартной структуры, не обеспечивают требуемую эффективность анализа подобных медицинских данных, да и многих других «малых» данных. Впрочем, разработка методов правильного формирования обучающей выборки актуальна и в других случаях. И многие специалисты полагают, 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 формирование набора данных. По большому счету, машинное обучение большинством воспринимается как отрасль науки и технологий, которая занимается извлечением знаний из данных. В подавляющем большинстве учебников по данной отрасли набор данных считается изначально заданным. И далее начинается обсуждение вопросов их анализа, разделения на обучающую и тестовую выборки, подбор соответствующей модели обучения и т.д. В обучении «с учителем» подход выглядит достаточно простым: «вход – выход». При этом во многих случаях неизвестно, насколько адекватно закладываемая таким образом модель отображает действительность. В [1] отмечается, что в принятых моделях зачастую содержатся некорректные данные, далекие от реальности. Причем последнее связано не с методами или точностью измерений, а с пониманием проблемы. Получается, что сами данные отражают не объективную реальность и сущность проблемы, а восприятие этой сущности тем, кто формировал эти данные. Как следствие, в представленных для обучения наборах данных реальные знания или отсутствуют, или неполны, или содержат значительные искажения. В таких случаях методы машинного обучения оказываются бессильными. Автоматически возникает проблема: насколько можно доверять получаемым результатам? Уже в момент постановки задачи может возникнуть следующий предмет внимания: насколько в предлагаемой модели мы сможем использовать потенциал ИИ, его «творческие» возможности, насколько будут понятны результаты его работы конечному пользователю и т.п.?

Очевидным представляется вывод, что первоначальная модель должна формироваться опытным экспертом, хорошо разбирающимся в проблемах предметной области. Еще лучше, если участвовать будет группа экспертов. В последнем случае могут быть использованы весьма неплохо разработанные методы экспертных оценок.

Учитывая, что ошибки, возникшие на этапе первоначального моделирования, можно отнести к группе сложнообнаруживаемых, возможно частичное решение задачи методами объяснимого искусственного интеллекта. Например, в [2] предложен способ обоснования предлагаемого решения с помощью гибридного подхода. А именно за счет интеграции искусственных нейронных сетей, традиционно обладающих максимально высокой точностью, с ансамблем интерпретируемых моделей ИИ, механизмы которых достаточно прозрачны и поддаются описанию, решается задача повышения интерпретируемости решений математических мо-

делей при сохранении высокой точности предсказаний. В том числе в данной работе предложен метод формирования обоснования на основе решений ансамбля, согласованных с предсказанием нейросети. Согласование достигается путем сравнения степеней уверенности моделей после предварительной калибровки, необходимость которой обусловлена эффектом избыточной уверенности (*overconfidence*), характерным для некоторых моделей машинного обучения. Разработан метод выбора интерпретируемых моделей ансамбля классификаторов, чьи оценки на конкретном объекте максимально близки по степени уверенности к выходу нейронной сети. Предлагаемый подход позволяет не только формировать обоснования, содержащие аргументы в пользу принятого решения, но и высказывать возможные альтернативные мнения. В принципе квалифицированный пользователь подобной системы ИИ в состоянии будет понять и ошибки первоначального моделирования.

Далее перейдем к наиболее известным и, к сожалению, достаточно распространенным ошибкам данных, полученных посредством измерений. Это могут быть как пропуски данных, так и некорректные измерения, связанные с человеческим фактором. Остановимся на последнем как на наиболее распространенном источнике ошибок. Очень часто при проведении измерений пользуются приборами, не прошедшими в нужное время калибровку. При этом результаты могут казаться правдоподобными для человека, проводящего измерения, или даже для специалиста предметной области, проводящего их анализ, но критически некорректными при обучении СИИ. Кроме того, возможны изменения условий проведения измерений, иногда вызванные самыми добрыми побуждениями. Например, при проведении диагностики по термометрическим данным некоторые врачи иногда протирают область измерения спиртом. Это имеет смысл в некоторых конкретных ситуациях и может дать врачу дополнительную информацию, хотя не предусмотрено формальной методикой. При этом в соответствующую базу данных информация об изменении методики проведения измерений зачастую не заносится. Обучающая выборка, сформированная по смешанным данным без соответствующих меток вряд ли сможет дать удовлетворительный результат для любого алгоритма классификации.

Скорее всего, подобных ошибок при формировании обучающего набора данных удалось бы избежать, если бы измерения проводились специально подготовленным специалистом, которому была бы известна основная цель его действий. В реальности же все происходит по-другому. Измерения проводятся не для формирования «какой-то обучающей выборки», а для выработки диагностического решения и тактики лечения. Иногда различие целей может привести к некорректным измерениям с точки зрения создания системы ИИ, но вполне разумным и обоснованным для данного конкретного врача. Таким образом, задача обнаружения не только выбросов, но и любых артефактов остается крайне важной и интересной и еще ждет своего решения. Какие-то подходы в отдельных областях есть, в том числе с использованием искусственных нейронных сетей [3]. Однако, по всей видимости, задача далека от окончательного решения.

Более сложной проблемой является наличие ошибок в метках. Как отмечено выше, особую сложность данной задаче придает тот факт, что ошибки могут

быть связаны не только с погрешностью измерений, но и с релевантностью данных принятым моделям. Проблема недостоверных и некорректных меток в последние годы обозначилась практически во всех сферах применения методов искусственного интеллекта, но особенно она характерна для медицинских данных. Достаточно интересный подход анонсирован в [4]. В нем редактирование меток, не соответствующих признаковому описанию объектов, осуществляется с помощью методов машинного обучения, в том числе искусственных нейронных сетей. При этом система сама в состоянии корректировать обучающую выборку в части доопределения и изменения меток различных классов.

Следующей крайне распространенной проблемой является несбалансированность данных. Как правило, при решении различных задач модели машинного обучения должны быть непредвзятыми и в равной степени определять объекты как мажоритарного класса, так и миноритарного. Обычно обращают внимание только на количественную балансировку. В то же время важна и равнозначность оценивания месторасположения объектов в признаковом пространстве (см., например, [5]).

Весьма перспективным выглядит подход к формированию обучающих наборов данных, который заключается в создании и использовании компьютерных моделей, с достаточно высокой степенью описывающих природу исследуемых объектов (см., например, [6]). Построенный за счет подобных моделей набор данных позволяет в большой мере решить обозначенные проблемы, так как 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. Во-первых, отметим крайне высокие требования к адекватности модели. Во-вторых, из-за сложной структуры компьютерных моделей возникают проблемы в управляемом получении набора данных, обладающего заранее заданными свойствами. В-третьих, при компьютерном моделировании 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.

Финансирование. Исследование выполнено за счет гранта Российского научного фонда № 25-21-00330, <https://rscf.ru/project/25-21-00330/>

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. Vol. 29. P. 115–119.
2. Попов И. Е. Интерпретация математических моделей по данным микроволновой радиотермометрии // *Математическая физика и компьютерное моделирование*. 2025. Т. 28, № 2. С. 62–80.
3. Ясницкий Л. Н., Плотникова Е. Г. Нейросетевой алгоритм выявления и удаления выбросов в зашумленных наборах данных // *Прикладная информатика*. 2024. Т. 19, № 5 (113). С. 88–100.
4. Лосев А. Г., Резникова А. С., Попов И. Е. Формирование оптимальной обучающей выборки методами машинного обучения для улучшения эффективности скрининга рака молочной железы // *Материалы научной сессии ВолГУ. Волгоград, 2023*. С. 82–87.

5. Лосев А. Г., Попов И. Е., Резникова А. С. Повышение репрезентативности обучающего набора данных за счет пространственной балансировки // Информатика и автоматизация. 2025. Т. 24, № 4. С. 1114–1156.

6. Levshinskii V., Polyakov M., Losev A., Khoperskov A. V. Verification and Validation of Computer Models for Diagnosing Breast Cancer Based on Machine Learning for Medical Data Analysis // Communications in Computer and Information Science. 2019. Vol. 1083. P. 63–67.

7. 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. Vol. 215. Article 106611.

CREATION OF TRAINING DATASETS: PROBLEMS AND PROSPECTS

Alexander G. Losev

Volgograd State University

100, Universitetsky Pr., Volgograd, Russia, 400062

alexander.losev@volsu.ru

This article addresses one of the key challenges in artificial intelligence: developing methods for generating training datasets. The causes of incorrect data and possible approaches to minimizing them are analyzed. In addition, modern strategies for constructing training datasets are considered, including spatial balancing, computational modeling, and surrogate modeling.

Keywords: data mining, computer modeling, explainable artificial intelligence

О БЕДНЫХ ДАННЫХ ЗАМОЛВИТЕ СЛОВО...

Зотина Галина Витальевна

Институт компьютерных наук и технологий
при Пермском государственном национальном исследовательском университете
614990, Россия, г. Пермь, ул. Букирева, 15
pastuhova13@yandex.ru

Жигалов Кирилл Олегович

Институт компьютерных наук и технологий
при Пермском государственном национальном исследовательском университете
614990, Россия, г. Пермь, ул. Букирева, 15
zhigalov-k@inbox.ru

Патакина Анастасия Сергеевна

Академическая школа информационных технологий
при Пермском государственном национальном исследовательском университете
614002, Россия, г. Пермь, ул. Чернышевского, 28
patakina@gmail.com

Сложно описать ценность данных в современном мире, еще сложнее оценить их бедность, как ее распознать и как с ней бороться. Среди способов решения проблемы бедности данных особо интересны подходы к получению синтетических или искусственных данных в сфере медицины.

Ключевые слова: данные, синтетические данные, искусственные данные, цифровой двойник

Введение. Согласно ГОСТ Р 52653-2006, данные – это представление информации в формализованном виде, пригодном для передачи, интерпретации и обработки. Согласно же ГОСТ 7.0-99, данные – это информация, обработанная и представленная в формализованном виде для дальнейшей обработки. Определение данных в Кембриджском словаре следующее: это информация, особенно факты и числа, собранные для последующего использования при принятии решений.

Одна из наиболее удачных и актуальных на сегодняшний день аналогий заключается в том, что данные называют нефтью цифровой экономики.

Исходно понятие данных – философское, оно возникает в эпистемологии при рассмотрении основной проблемы гносеологии – познаваемости мира, поиска и осмысления истины. Процедуры верификации или фальсификации данных создают информацию, осмысление истины создает знание. Философия рассматривает преобразование сведений в данные, данных в информацию, а информации – в знания. Истинность сведений субъективна. Сведения, выраженные в формальном представлении, являются данными. Обработка данных позволяет определить, сколько в них содержится информации. При осмыслении информации экспертом создаются знания.

Бедность данных. Под бедностью данных понимается многое: слабая их формализация, неструктурируемость, невозможность их обобщить или, наоборот,

неудачные основания для классификации, не дающие нужный результат, но чаще всего – их малое количество и низкое качество. В любом случае речь идет про обработку данных некими алгоритмами, в основном на основе методов машинного обучения и искусственного интеллекта, для решения вполне определенной задачи.

Синтетические данные. Наиболее остро с отсутствием данных столкнулась медицина. Острота подчеркивается попытками создать и нормативную базу, и инфраструктуру для хранения данных, и механизмы передачи данных, и многое прочее. В марте 2025 г. по предложению Европейской комиссии создано Европейское пространство медицинских данных (European Health Data Space, EHDS) [1, 2]. Ключевым элементом этой инициативы являются синтетические данные.

Одно из первых определений синтетических данных, которое было отражено в официальных документах Бюро переписи населения США от 2021 г., определяет «синтетические данные в компьютерном программировании как полностью смоделированные конструкции для тестирования, не ограниченные реальными условиями». В то же время в документе оговаривается, что в статистике синтетические данные часто представляют собой объединение естественных данных из неких различных источников [1, 3].

Еще один документ – глоссарий Управления по санитарному надзору за качеством пищевых продуктов и медикаментов США (FDA) по вопросам цифрового здравоохранения и искусственного интеллекта – содержит следующее: «Данные, созданные искусственно (например, с помощью статистического моделирования, компьютерного моделирования), в результате чего генерируются новые значения и/или элементы данных. Как правило, синтетические данные призваны отражать структуру, свойства и взаимосвязи, наблюдаемые в реальных данных...» [1, 4].

Важно отметить, как определяются наблюдаемые (или истинные, или естественные, или реальные) данные – это данные, полученные в результате непосредственного измерения или сбора информации о реальных событиях, в том числе в ходе рандомизированных контролируемых исследований [5].

Будем различать два основных класса синтетических данных (подход на основе реальных данных и подход на основе воссоздания процесса):

- 1) данные, полученные из реальных, различными, в основном комбинаторными, методами. В качестве примера можно привести искусственно созданное лицо из «кусочков» лиц реальных людей;
- 2) данные, полученные при моделировании (имитации, симуляции) какого-либо процесса.

К последним также будем относить и данные, полученные в результате технологии цифрового двойника, которая и является, по сути, результатом моделирования некого процесса и/или объекта, в процессе своего существования и функционирования.

Одно из наиболее масштабных исследований по генерации синтетических медицинских данных было проведено европейскими консорциумами GenoMed4All и Synthema при поддержке EuroBloodNET (Европейская справочная сеть по редким гематологическим заболеваниям). Исследование было зарегистрировано на сайте ClinicalTrials.gov (идентификатор: NCT04889729). Критериями включения были

возраст ≥ 18 лет, диагноз: миелоидное новообразование (либо миелодиспластический синдром, либо острый миелодиспластический синдром), доступная информация о демографии, клинических особенностях, скрининге мутаций/хромосомных аномалий, лечении и выживаемости. Всего было включено 7133 пациента. Для генерации синтетических данных была реализована условно-генеративная состязательная сетевая архитектура [6].

Итог исследования: «...На основе данных о 944 пациентах с МДС, доступных с 2014 г., мы создали синтетическую когорту, увеличенную на 300%, и спрогнозировали развитие молекулярной классификации и системы молекулярного ранжирования, которые были получены много лет спустя на основе данных о 2043–2957 реальных пациентах соответственно. Кроме того, на основе данных о 187 пациентах с МДС, участвовавших в клиническом исследовании луспатерцепта, мы создали синтетическую когорту, которая воспроизводила все клинические конечные точки исследования. Наконец, мы разработали веб-сайт, который позволяет врачам генерировать высококачественные синтетические данные на основе существующего биобанка реальных пациентов» [6].

Впечатляющие результаты исследования стимулируют аналогичные разработки, но порой ошибки подобных исследований катастрофичны. Примером недостатка данных и попытки их компенсировать может послужить опыт научного коллектива под руководством Ненада Томашева [7], который заключался в разработке алгоритма глубокого обучения для прогнозирования острого повреждения почек у взрослых. Только 6,4% в обучающем наборе данных были получены от пациентов женского пола, и, как и ожидалось, модель оказалась неэффективной в этой группе, воссоздать корректно данные не представилось возможным.

В этом году в России принят Кодекс этики применения искусственного интеллекта в сфере охраны здоровья, утвержденный Межведомственной рабочей группой при Минздраве России по вопросам создания, развития и внедрения в клиническую практику медицинских изделий и сервисов с использованием технологий искусственного интеллекта 14 февраля 2025 г. № 90/18-0/117 [7]. В тексте документа нет терминов, связанных с созданием и использованием синтетических данных, основной упор сделан на определение этических норм использования искусственного интеллекта.

Библиографический список

1. Pasculli G., Virgolin M., Myles P. et al. Synthetic Data in Healthcare and Drug Development: Definitions, Regulatory Frameworks, Issues // CPT: Pharmacometrics & Systems Pharmacology. 2025. Vol. 14. P. 840–852. DOI [10.1002/psp4.70021](https://doi.org/10.1002/psp4.70021)
2. Европейское пространство медицинских данных. 2023 // Европейская комиссия. URL: https://health.ec.europa.eu/ehealth-digital-health-and-care/european-health-data-space_en
3. Что такое синтетические данные? // Бюро переписи населения США. 2021. URL: <https://www.census.gov/about/what/synthetic-data.html>
4. FDA Digital Health and Artificial Intelligence Glossary – Educational Resource. 2025. URL: <https://www.fda.gov/science-research/artificial-intelligence-and-medical-products/fda-digital-health-and-artificial-intelligence-glossary-educational-resource#>
5. D'Amico S., Dall'Olio D., Sala C. et al. Synthetic Data Generation by Artificial Intelligence to Accelerate Research and Precision Medicine in Hematology // JCO Clinical Cancer Informatics. 2023. Vol. 7. e2300021. DOI [10.1200/CCI.23.00021](https://doi.org/10.1200/CCI.23.00021)

6. Tomašev N., Glorot X., Rae J. W. et al. A clinically applicable approach to continuous prediction of future acute kidney injury // Nature. 2019. Vol. 572. P. 116–119. DOI [10.1038/s41586-019-1390-1](https://doi.org/10.1038/s41586-019-1390-1)

7. Кодекс этики применения искусственного интеллекта в сфере охраны здоровья. Версия 2.1 // Гарант. URL: <https://www.garant.ru/products/ipo/prime/doc/411615533/?ysclid=me9wiiqorf941831979>

ABOUT POOR DATA, SPEAK A WORD...

Zotina Galina Vitalievna

Institute of Computer Science and Technology at Perm State University
15, Bukireva Str., Perm, Russia, 614990
pastuhova13@yandex.ru

Zhigalov Kirill Olegovich

Institute of Computer Science and Technology at Perm State University
15, Bukireva Str., Perm, Russia, 614990
zhigalov-k@inbox.ru

Patakina Anastasia Sergeevna

Academic School of Information Technologies at Perm State University
28, Chernyshevskogo Str., Perm, Russia, 614002
patakina@gmail.com

It is difficult to describe the value of data in the modern world, and it is even more difficult to assess its poverty, how to recognize it and how to deal with it. Among the ways to solve the problem of data poverty, approaches to obtaining synthetic or artificial data in the field of medicine are particularly interesting.

Keywords: data, synthetic data, artificial data, digital twin

АЛГОРИТМ СЕЛЕКЦИИ ОСОБЫХ ТОЧЕК НА СНИМКАХ ВИДЕОРЕЯДА

Кузьмин Александр Алексеевич

Коробков Сергей Васильевич

Жилин Илья Анатольевич

Юго-Западный государственный университет,
305000, Россия, г. Курск, ул. 50 лет Октября, 94
ku3bmin@gmail.com

Для повышения точности определения координат блобов на снимках предложено использовать агрегированный блоб, что позволило применить для формирования вектора информативных признаков принцип многооконного сканирования. При этом первое окно формирует информативные признаки для нейросетевого классификатора агрегированного блоба, а второе окно сканирует первое окно, если оно определено нейросетевым классификатором как область ROI.

Ключевые слова: особые точки типа блоб, алгоритм поиска особых точек, многооконное сканирование, нейронная сеть

Введение. Обнаружение аномальных объектов, или особых точек, на изображениях и видеопоследовательностях – очень важная и востребованная область компьютерного зрения. Задачи такого плана возникают при поиске реперных точек в системе управления беспилотными летательными аппаратами (БПЛА) или наземными роботами, при анализе видеоряда изображений анатомического органа в медицинской диагностике, поиске источника возгорания на спутниковых снимках, обнаружения лиц в системах контроля и наблюдения и многом другом [1–4].

При анализе и классификации последовательностей снимков видеоряда обычно имеют дело с особыми точками типа блоб (пятно). В настоящее время известно множество различных подходов к поиску блобов. Современные технологии, а также классические методы обработки изображений, обеспечивающие их улучшение и информативность, позволяют распознать и классифицировать блобы на достаточно зашумленных и искаженных изображениях [5–7]. Однако по мере развития современных технологий в робототехнике, БПЛА и медицине, ужесточаются требования к точности и оперативности принятия решений, поэтому методы классификации блобов требуют дальнейшего совершенствования.

При работе с блобами необходимо решить две задачи. Первая задача – это выбор самого блоба. Эту задачу часто возлагают на лицо, принимающее решение (ЛПР). Однако очень часто реперную точку приходится выбирать в автоматическом режиме, например при переходе БПЛА в автономный режим полета [8, 9]. Вторая задача – поиск блоба на снимках видеоряда – синтез дескрипторов и детекторов блобов. В данной работе мы остановимся на решении второй задачи,

полагая, что сам блок уже выбран. Для улучшения производительности детектора блоков используют набор обобщенных фильтров LoG (gLoG) [10, 11]. Адаптивные фильтры позволяют сформировать несколько векторов дескрипторов, каждому из которых соответствует свой обучаемый классификатор. Агрегация решений этих классификаторов позволяет как повысить точность классификации блока, так и отстроиться от ряда помех, приводящих к ошибочной классификации. Тем не менее использование адаптивной фильтрации не приводит к окончательной отстройке от ложноположительных результатов, что требует дальнейшего совершенствования алгоритмов классификации [12, 13].

Методы. Анализ снимков видеоряда показывает, что выбор реперной точки на снимке весьма сложен. Достаточно яркие объекты позволяют использовать их в качестве блоков, однако их много и они на снимке расположены в хаотическом порядке, что затрудняет их идентификацию на других снимках видеоряда. Более того, в качестве блоков могут выступать как наиболее яркие, так и наиболее темные объекты на снимке, что затрудняет их классификацию с использованием экстремальных корреляционных методов [14, 15]. Поэтому целесообразно выбрать несколько близко отстоящих объектов на снимке и связать их геометрической фигурой, в качестве которой мы использовали треугольник.

На рис. 1 показана агрегированная особая точка, состоящая из трех блоков, образующих треугольники ABC и $A_1B_1C_1$ на двух смежных снимках.




Рис. 1. Агрегированная особая точка, представленная в виде трех блоков на двух смежных снимках

Сформировав особую точку в виде треугольника, мы автоматически получаем алгоритм описания его дескрипторов, а также упрощаем поиск его на смежных снимках. Учитывая, что блоки, входящие в агрегированный блок, жестко связаны между собой, мы можем зафиксировать точку внутри периметра треугольника ABC , координаты которой также априорно известны из предшествующего снимка, и использовать ее в качестве дополнительной реперной точки. В качестве такой точки можно использовать либо координаты центра вписанной


в треугольник окружности, либо координаты центра тяжести треугольника. В данной работе использовались координаты центра тяжести треугольника, который определяется по формулам [15]

$$x_{ug} = \frac{x_i + x_j + x_k}{3}, \quad y_{ug} = \frac{y_i + y_j + y_k}{3}, \quad (1)$$

где векторы $a(x_i, y_i)$, $b(x_j, y_j)$, $c(x_k, y_k)$ определяют соответствующие координаты вершин треугольников.

Таким образом, алгоритм поиска блока на смежных снимках в видеоряде можно декомпозировать на два этапа. На первом этапе дескрипторы формируются путем сканирования снимка окном, превышающим размеры агрегированной особой точки. Дескрипторы подаются на обучаемый классификатор NET1. Если он принимает решение, что координаты окна являются координатой центра тяжести треугольника, образованного координатами вершин блоков, входящих в агрегированную особую точку, то это окно отмечается как область ROI. На этом заканчивается первый этап селекции координат агрегированного блока.

На рис. 2 представлены области ROI, которые отмечены как координаты центра тяжести треугольников, образующих агрегированную особую точку.



Примечание. ▲ – координаты первого сканирующего окна, отмеченные классификатором NET1 как области ROI; ■ – действительная координата центра треугольника, образующего агрегированную особую точку.

Рис. 2. Гистограмма распределения координат претендентов на центр агрегированной особой точки

Так как возможны ложноположительные срабатывания NET1, то используем критерий, полученный по множествам координат центров тяжести агрегированной особой точки [15]:

$$\Delta r_g = \sqrt{(x_u - x_{ug})^2 + (y_u - y_{ug})^2}, \quad (2)$$

где (x_u, y_u) – координаты центра тяжести агрегированного блока-эталона, (x_{ug}, y_{ug}) – координаты центров тяжести треугольников.

Если (3) не превышает значение порога θ , то данная триада остается в качестве претендента на координаты агрегированного блока.

Если критерий (2) не превышает пороговый, то соответствующая триада вершин треугольника попадает в пул координат-претендентов агрегированного блока и ей присваивается соответствующий индекс g .

Второй этап селекции основан на том, что блоки, входящие в агрегированную особую точку, жестко связаны между собой. Поэтому мы можем зафиксировать точку (x_{ug}, y_{ug}) внутри периметра треугольника ABC, координаты которой определены на первом этапе, и из всех множеств ROI выбрать наиболее подходящий по определенному критерию, который определяется на втором этапе.

В этом случае области ROI сканируется вторым окном, размеры которого определяются в соответствии с размерами блоков, включенных в агрегированную особую точку. Второе окно формирует дескрипторы, которые подаются на входы промежуточных классификаторов NET2, NET3, NET4.

На рис. 3а показан фрагмент с агрегированным блоком. Изображение искусственно зашумлено гауссовским шумом, среднее квадратическое отклонение (СКО) этого фрагмента составляет 50 [15]. На рис. 3б показаны координаты областей ROI, полученные на первом этапе.




Рис. 3. Иллюстрация этапов поиска координат агрегированной особой точки

Решения классификаторов NET2, NET3, NET4 подаются на входы агрегатора NET5, который принимает решение об идентификации агрегированной особой точки. На рис. 3в представлены решения этого агрегатора.

Заключение

1. Для повышения точности определения координат блоков на снимках видеоряда предложено формировать агрегированную особую точку из трех особых точек, являющихся координатами вершин треугольника.

2. Для поиска особых точек типа блок на снимках видеоряда предложен алгоритм двухэтапного определения координат агрегированного блока. На первом этапе определяются координаты окна, соответствующего центрам тяжести агрегированного блока, которые рассматриваются как области ROI. На втором этапе определяются координаты вершин треугольника, центр тяжести которого наиболее близок к центру тяжести агрегированного блока.

3. В среде Матлаб осуществлено моделирование предложенных алгоритмов поиска особых точек. Алгоритмы показали свою работоспособность при высоком уровне помех, моделируемых на изображении посредством гауссова шума.

4. Формирование агрегированной особой точки позволяет повысить точность определения его координат, а также дает возможность минимизировать накапливающиеся ошибки на участке двух смежных снимков.

Библиографический список

1. Filist S., Al-Kasasbeh R. T., Tomakova R. A. et al. Automated system for classifying images of video streams for timely detection of fires // *International Journal of Remote Sensing*. 2024. Vol. 45. P. 8157–8180. DOI [10.1080/01431161.2024.2398818](https://doi.org/10.1080/01431161.2024.2398818)
2. Khan A., Gupta S., Gupta S. K. Multi-hazard disaster studies: Monitoring, detection, recovery, and management, based on emerging technologies and optimal techniques // *International Journal of Disaster Risk Reduction*. 2020. Vol. 47. Article 101642.
3. Филист С. А., Томакова Р. А., Брежнева А. Н. и др. Клеточные процессоры в классификаторах многоканальных изображений // *Радиопромышленность*. 2019. Т. 29, № 1. С. 45–52.
4. Филист С. А., Дабагов А. Р., Томакова Р. А. и др. Метод каскадной сегментации рентгенограмм молочной железы // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2019. Т. 9, № 1. С. 49–61.
5. Kumar A. SURF feature descriptor for image analysis // *Imaging and Radiation Research*. 2023. Vol. 6, iss. 1. Article 5643. DOI [10.24294/irr.v6i1.5643](https://doi.org/10.24294/irr.v6i1.5643)
6. Lowe D. G. Distinctive image features from scale-invariant keypoints // *IJCV*. 2004. Vol. 60, no. 2. P. 91–110.
7. Филист С. А., Томакова Р. А., Шаталова О. В. и др. Метод классификации сложноструктурируемых изображений на основе самоорганизующихся нейросетевых структур // *Радиопромышленность*. 2016. № 4. С. 57–65.
8. Филист С. А., Шевцов М. В., Белозеров В. А. и др. Автоматизированная система для классификации снимков видеопотоков // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2021. Т. 11, № 4. С. 85–105.
9. Filist S., Al-Kasasbeh R. T., Tomakova R. A. et al. An unmanned aerial vehicle autonomous flight trajectory planning method and algorithm for the early detection of the ignition source during fire monitoring, *International Journal of Remote Sensing*. 2024. Vol. 45, no. 12. P. 4178–4197. DOI [10.1080/01431161.2024.2358451](https://doi.org/10.1080/01431161.2024.2358451)
10. Kong H., Akakin H. C., Sarma S. E. A Generalized Laplacian of Gaussian Filter for Blob Detection and Its Applications // *IEEE Transactions on Cybernetics*. 2013. Vol. 43, no. 6. P. 1719–1733.
11. Филист С. А., Дабагов А. Р., Томакова Р. А. и др. Многослойные морфологические операторы для сегментации сложноструктурируемых растровых полутоновых изображений // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2019. Т. 9, № 3. С. 44–63.
12. Lindeberg T., Garding J. Shape-adapted smoothing in estimation of 3-D shape cues from affine deformations of local 2-D brightness structure // *Image and Vision Computing*. 1997. Vol. 15, no. 6. P. 415–434.
13. Dusmanu M., Rocco I., Pajdla T. et al. D2-Net: A Trainable CNN for Joint Description and Detection of Local Features // *arXiv:1905.03561v1 [cs.CV]* 9 May 2019.
14. Дюдин М. В., Зуев И. В., Филист С. А., Чудинов С. М. Автоматические классификаторы сложно структурируемых изображений на основе мультиметодных технологий многокритериального выбора // *Вопросы радиоэлектроники. Серия «Системы и средства отображения информации и управления спецтехникой» (СОИУ)*. 2015. № 1. С. 130–140.
15. Горбачев И. Н., Томакова Р. А., Коробков С. В. Методы и алгоритмы идентификации особых точек на снимках, полученных с бортового фото-видеорегистратора беспилотного летательного аппарата // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2025. Т. 15, № 1. С. 91–116.

ALGORITHM FOR SELECTION OF SPECIAL POINTS IN VIDEO SEQUENCE IMAGES

Alexander A. Kuzmin, Sergey V. Korobkov, Ilya A. Zhilin

Southwestern State University
94, 50 years of October Str., Kursk, Russia, 305000
ku3bmin@gmail.com

To improve the accuracy of blob coordinate determination in images, we proposed using an aggregated blob, which allowed us to apply the principle of multi-window scanning to generate a vector of informative features. The first window generates informative features for the aggregated blob neural network classifier, and the second window scans the first window if it is identified by the neural network classifier as an ROI.

Keywords: blob keypoints, keypoint search algorithm, multi-window scanning, neural network

НЕЙРОСЕТЕВОЙ МЕТОД ПОИСКА ВЫБРОСОВ НА ОСНОВЕ АНАЛИЗА НАКОПЛЕННОЙ ОШИБКИ ОБУЧЕНИЯ

Голдобин Максим Алексеевич

Пермский государственный гуманитарно-педагогический университет,
614990, Россия, г. Пермь, ул. Сибирская, 24
goldmaxprof@rambler.ru

В статье предложен новый нейросетевой метод поиска выбросов статистической информации. Метод основан на анализе поведения накопленной ошибки обучения множества нейросетей персептронного типа с одним скрытым слоем, полученной суммированием для каждого примера обучающего набора данных. Количество нейронов скрытого слоя каждой нейросети определяется исходя из следствия теоремы Арнольда – Холмогорова – Хехт-Нильсена, которое регламентирует количество связей и количество нейронов скрытого слоя, необходимых для получения достаточной обобщающей способности нейросети с учетом размеров входного и выходного слоев.

Ключевые слова: нейронная сеть, выброс, накопленная ошибка, ошибка обучения

Введение. Отклонения в статистических данных, вызванные погрешностями приборов, недостаточной квалификацией персонала, случайными ошибками, полученными во время сбора или обработки информации, затрудняют создание точных экспертных систем и моделей машинного обучения. Классические статистические методы и методы на основе расстояний для выявления выбросов часто неэффективны при обнаружении некоторых типов аномалий и могут ошибочно классифицировать нормальные данные как выбросы. Альтернативой становятся нейросетевые методы. В статье описывается новый нейросетевой метод, который базируется на анализе накопленной ошибки обучения множества однослойных персептронов, получаемой суммированием ошибок для каждого примера обучающего набора данных.

Идея метода. В работах [1, 2] для обнаружения выбросов предлагается использовать специальные нейронные сети персептронного типа с одним скрытым слоем, которые способны показывать наибольшую ошибку обучения на примерах, являющихся выбросами. В статье [1] представлен алгоритм создания и применения нейронных сетей, пригодных для выявления выбросов.

В [1] для обнаружения выбросов предлагается использовать нейронные сети, количество нейронов скрытого слоя которых определяется соотношением

$$N = N_{min} + \xi (N_{max} - N_{min}), \quad (1)$$

где N_{max} и N_{min} – максимальное и минимальное количество нейронов скрытого слоя, необходимые для обеспечения наилучшего обобщающего свойства:

$$N_{min} = \frac{N_y Q}{((1 + \log_2(Q))(N_x + N_y))}, \quad (2)$$

$$N_{max} = \frac{N_y}{N_x + N_y} \left(\left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + 1 \right). \quad (3)$$

В формулах (2), (3) N_x – количество нейронов входного слоя, N_y – количество нейронов выходного слоя, а Q – количество наблюдений набора данных.

Формулы (1), (2) и (3) являются обобщением следствия из теоремы Арнольда – Колмогорова – Хехт-Нильсена. Параметр ξ предлагается брать в пределах полученного эмпирически на модельных примерах интервала $[-0,007; 0,004]$. Однако малые величины коэффициента ξ приводят к тому, что рекомендуемое для специальной нейросети количество нейронов скрытого слоя становится равным N_{min} .

Автор настоящей статьи заметил, что существует несколько нейросетей с разным количеством нейронов на скрытом слое, которые одинаково эффективно выявляют выбросы. Известно, что обучаемость нейросети зависит от числа синаптических связей, а с увеличением количества нейронов на скрытом слое она должна возрасть, приводя к уменьшению ошибки обучения.

Принимая во внимание следствие из теоремы Арнольда – Колмогорова – Хехт-Нильсена [1, 2], определяющее интервал количества нейронов на скрытом слое, обеспечивающий достаточную обобщающую способность, который задается формулами (2) и (3), можно предположить, что некоторые сети из этого интервала могут быть эффективными для определения выбросов. Также принимая во внимание следствие из теоремы Цыбенко [3] об универсальной аппроксимации (при аппроксимации нейросетью с одним скрытым слоем всегда найдется достаточное количество нейронов для аппроксимации с любой точностью), следует заметить, что суммирование за пределами значения N_{max} не имеет смысла. Ошибка обучения нейросетей с большим, чем N_{max} , количеством нейронов на скрытом слое будет лишь уменьшаться и не будет вносить вклад в накопленную ошибку для любого из примеров обучающего множества. Поэтому верхняя граница интервала может быть задана в качестве параметра рассматриваемого метода.

На основе этого была выдвинута гипотеза, что суммарная ошибка обучения для каждого примера, рассчитанная по всем нейросетям с числом нейронов в скрытом слое из диапазона $[N_{min}, N_{max}]$, способна лучше определять выбросы, чем отдельно подобранная сеть. Идея заключается в том, что по мере увеличения числа нейронов и связей модель точнее аппроксимирует данные обучающего множества, снижая ошибки по обычным примерам, тогда как для выбросов суммарная ошибка будет существенно выше. Таким образом, суммирование ошибок по множеству вариантов нейросетей улучшает идентификацию аномалий.

Выполненные модельные эксперименты и проверка метода в случаях решения реальных задач [4-8], показала, что не всегда нейросеть с количеством нейронов равным N_{min} правильно идентифицирует выбросы, поэтому суммирование следует начинать с $N_{min} + 1$. Это связано с тем, что N_{min} нейронов на скрытом слое далеко не во всех случаях обеспечивает достаточную гибкость или обучаемость нейросети.

Исходя из изложенного, предлагается следующий вариант алгоритма для реализации метода.

1. Вычисление N_{max} и N_{min} . Определение верхней границы интервала N_{lim} , $N_{lim} \geq N_{min} + 1$.

2. Аппроксимация нейросетями с количеством нейронов на скрытом слое $N \in [N_{min}, N_{lim}]$.

3. Вычисление величины накопленной ошибки для каждого примера обучающего множества.

4. Анализ кривой накопленной ошибки.

5. Поиск примера с наибольшей накопленной ошибкой обучения. Если величина накопленной ошибки для этого примера выходит за границу двух среднеквадратичных отклонений, то данный пример считается выбросом и удаляется из обучающего множества.

6. Процесс повторяется до тех пор, пока величины накопленных ошибок всех примеров не будут находиться в пределах двух среднеквадратичных отклонений.

Вычислительный эксперимент. Проверка гипотезы была выполнена на нескольких модельных экспериментах, один из которых представлен на рис. 1. На этом рисунке показан пример параболической зависимости $y = (x - 6)^2$, взятый из статьи [1]. В отличие от примера из статьи [1], где рассматривается случай с одним выбросом, в данном случае добавлено три выброса разной силы в точках $B(15; 150)$, $D(6; 6)$ и $E(10; 0)$.




Рис. 1. Пример нелинейной зависимости $y = (x - 6)^2$ в случаях наличия трех выбросов в точках $B(15; 150)$, $D(6; 6)$ и $E(10; 0)$

В рассматриваемом примере полное обучающее множество состоит из 21 примера. Используя формулы (2) и (3) для 21 примера, получаем $N_{min} = 2$, $N_{max} = 32$. Суммирование ошибок проводилось для нейросетей, количество нейронов на скрытом слое которых было в интервале $[N_{min} + 1, N_{max}]$, т.е. в интервале $[3, 32]$.

На рис. 2,а видно, что максимальная накопленная ошибка обучения наблюдается в точке $x = 15$, что закономерно, ведь в этой точке было заведомо задано наибольшее отклонение от параболы. Кривая накопленной ошибки не показывает наличие выбросов в точках $x = 10$ и $x = 6$. После удаления обучающего примера, соответствующего выбросу $x = 15$, явно стали проявляться максимумы в точках $x = 10$ и $x = 6$, рис. 12,б, причем при $x = 10$ значение накоплен-

ной ошибки больше, чем при значении $x = 6$. После удаления выброса, соответствующего точке $x = 10$, на кривой накопленной ошибки остается один максимум, рис. 12,в. И наконец, после удаления всех выбросов кривая накопленной ошибки перестала содержать явные максимумы, рис. 12,г.




Рис. 2. Кривые ACC_MID осредненных накопленных ошибок обучения нейросетей в случаях: *а* – при наличии всех трех выбросов, *б* – при отсутствии выброса в точке $x = 15$, *в* – после удаления выбросов в точках $x = 15$ и $x = 10$, *г* – при отсутствии выбросов

Проанализировать результаты можно с помощью статистического анализа, используя величину отклонения в каждой точке и положение каждой из точек относительно зон стандартного отклонения. Во всех случаях с наличием выбросов наблюдается хотя бы один максимум, попадающий в зону 2σ от среднего значения «MID». То есть в качестве порога на выявление ошибок можно взять границу в два стандартных отклонения 2σ . Но следует учитывать, что некоторые соседние к выбросам точки также могут иметь отклонения, выходящие за границу 2σ , рис. 2,а. Поэтому в качестве выброса необходимо определять пример только с наибольшей накопленной ошибкой обучения.

Следует заметить, что не всегда необходимо проводить суммирование в пределах всего интервала $[N_{min}+1, N_{max}]$, так как наибольший вклад вносят сети, принадлежащие началу этого интервала. Такой подход особенно актуален, если размерность задачи повышается и увеличивается количество примеров обучающего множества, когда значительно повышается трудоемкость метода.

Заключение. В статье предложен новый нейросетевой метод обнаружения выбросов, который, по сути, является модификацией метода [1, 2]. Предложенный новый метод основан на идее о том, что по мере увеличения числа нейронов и связей модель точнее аппроксимирует данные обучающего множества, снижая ошибки по обычным примерам, тогда как для выбросов суммарная ошибка будет существенно выше. Также предложен алгоритм данного метода.

В отличие от методов Сикачека [9] и автоэнкодеров [10–12], где эффективность зависит от используемых структур нейросетей, которые подбираются для каждой задачи индивидуально, в предложенном методе структура используемых нейросетей четко регламентируется.

Следует отметить, что нижняя рекомендованная граница интервала суммирования $N_{min} + 1$ может быть представлена выражением $N_{min} + (N_{max} - N_{min})/N_{max}$. Это является частным случаем формулы (1) при $\xi = 1/N_{max}$.

Данный метод был применен и оказался эффективен при выполнении многих проектов Пермской научной школы искусственного интеллекта [13, 14], в частности, рассмотренных в [4–8].

Финансирование. Работа выполнена при поддержке гранта Российского научного фонда № 22–61–00096, <https://rscf.ru/project/22-61-00096/> Главным исполнителем гранта является Национальный исследовательский университет «МЭИ».

Библиографический список

1. Ясницкий Л. Н., Плотникова Е. Г. Нейросетевой алгоритм выявления и удаления выбросов в зашумленных наборах данных // Прикладная информатика. 2024. Т. 19, № 5. С. 88–100. DOI 10.37791/2687-0649-2024-19-5-88-100
2. Yasnitsky L. N. Algorithm for searching and analyzing abnormal observations of statistical information based on the Arnold – Kolmogorov – Hecht–Nielsen theorem // International Journal of Advanced Trends in Computer Science and Engineering. 2020. Vol. 9, no. 2. P. 1814–1819. DOI 10.30534/ijatcse/2020/139922020
3. Cybenko G. Approximation by superpositions of a sigmoidal function // Mathematics of Control, Signals, and Systems. 1989. Vol. 2, no. 4. P. 303–314. DOI 10.1007/BF02551274
4. Ясницкий Л. Н., Голдобин М. А., Мезенцев А. С. Инструментальные средства для разработки мероприятий по снижению брака серийного производства (Обзорная статья) // Прикладная математика и вопросы управления. 2025 (в печати).
5. Голдобин М. А., Ясницкий Л. Н. Нейросетевое прогнозирование дефектов производства металлургической продукции // Прикладная информатика. 2024. Т. 19. № 1. С. 113–124. DOI 10.37791/2687-0649-2024-19-1-113-124.
6. Ясницкий Л. Н., Черепанов Ф. М., Голдобин М. А., Неверов А. Р. Нейросетевые модели влияния химического состава рудного сырья и параметров плавильных процессов на свойства изделий // Прикладная информатика. 2023. Т. 18, № 6. С. 109–119. DOI 10.37791/2687-0649-2023-18-6-109-119.
7. Голдобин М. А. Опыт создания нейросетевой системы анализа технологического процесса изготовления стержней для литья лопаток авиационных двигателей // Нейрокомпьютеры и их применение: тез. докл. XVIII Всерос. науч. конф. (Москва, 17 марта 2020 г.). М.: МГППУ, 2020. С. 303–306. EDN BPBVSR
8. Голдобин М. А., Морозов А. А., Ясницкий Л. Н. Нейросетевое прогнозирование и управление качеством литейных изделий // Материалы XIII Междунар. конф. по прикладной математике и механике в аэрокосмической отрасли (АММАИ2020). М., 2020. С. 640–641.
9. Sykacek P. Equivalent error bars for neural network classifiers trained by Bayesian inference // Proceedings of the European Symposium on Artificial Neural Networks (ESANN). 1997. P. 27.
10. Hawkins S., He H., Williams G., Baxter R. Outlier detection using replicator neural networks // Data Warehousing and Knowledge Discovery / Ed. by Y. Kambayashi, W. Winiwarter, M. Arikawa. Lecture Notes in Computer Science, vol. 2454. Berlin, Heidelberg, 2002. P. 170–180. DOI 10.1007/3-540-46145-0_17
11. Shchetinin E. On anomalies detection in electrocardiograms with unsupervised deep learning methods // Journal of Applied Informatics. 2022. Vol. 17, no. 6. P. 81–93 (In Russian). DOI 10.37791/2687-0649-2022-17-6-81-93
12. Abhaya A., Patra B. K. An efficient method for autoencoder based outlier detection // Expert Systems with Applications. 2023. Vol. 213, Part A. Article 118904. DOI 10.1016/j.eswa.2022.118904

13. 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. DOI 10.15593/2499-9873/2018.4.06

14. Yasnitsky L. N., Dumler A. A., Cherepanov F. M. Dynamic artificial neural networks as basis for medicine revolution // Advances in Intelligent Systems and Computing. 2018. Vol. 850. P. 351–358.

NEURAL NETWORK METHOD FOR OUTLIER DETECTION BASED ON ANALYSIS OF ACCUMULATED TRAINING ERROR

Goldobin M. A.

Perm State Humanitarian Pedagogical University,
24, Sibirskaya Str., Perm, Russia, 614990
goldmaxprof@rambler.ru

This article proposes a new neural network method for detecting outliers in statistical information. The method is based on analyzing the behavior of accumulated training errors of a set of perceptron-type neural networks with a single hidden layer, obtained by summing the errors for each example in the training dataset. The number of neurons in the hidden layer of each neural network is determined according to a corollary of the Arnold – Kolmogorov – Hecht-Nielsen theorem, which regulates the number of connections and neurons in the hidden layer required to achieve sufficient generalization capability of the neural network, considering the sizes of the input and output layers.

Keywords: neural network, outlier, accumulated error, training error, autoencoder

СРАВНЕНИЕ ВАРИАНТОВ ИНТЕРВАЛЬНОГО КОДИРОВАНИЯ ИСХОДНЫХ ДАННЫХ С ИСПОЛЬЗОВАНИЕМ УНИВЕРСАЛЬНОЙ КОГНИТИВНОЙ АНАЛИТИЧЕСКОЙ СИСТЕМЫ «ЭЙДОС-X++»

Елохов Алексей Сергеевич

Пермский национальный исследовательский политехнический университет
614068, Россия, г. Пермь, Комсомольский проспект, 29
elokhov@gmail.com

В статье рассматривается два варианта интервального кодирования одних и тех же исходных данных (показателей качества), полученных из системы мониторинга IP-сети, в системе «Эйдос-X++»: разбиение на разные интервалы с равным числом наблюдений и с равными интервалами с разным числом наблюдений.

Ключевые слова: IP-сети, Эйдос-X++, jitter, packet loss, latency, QoE

Введение. При анализе данных сетевого мониторинга в интеллектуальных системах, как правило, ключевую роль играет метод дискретизации непрерывных величин. Сетевые метрики (задержка, джиттер, потери пакетов, пропускная способность) представляют собой непрерывные величины с неравномерным распределением, что создает проблему выбора оптимального способа их разбиения на интервалы.

Фиксированные интервалы с равными диапазонами часто приводят к несбалансированным классам: большинство наблюдений концентрируется в отдельных диапазонах, что снижает точность предиктивных моделей. Адаптивное разбиение с равным числом наблюдений обеспечивает баланс классов, но усложняет интерпретацию границ для практического применения.

Настоящая работа представляет сравнительный анализ двух методов интервального кодирования данных мониторинга IP-сети в системе «Эйдос-X++» [1]: адаптивного (разные интервалы с равным числом наблюдений) и фиксированного (равные интервалы с разным числом наблюдений). Цель – определить метод, обеспечивающий более высокую достоверность классификации, и сформулировать рекомендации по выбору подхода в зависимости от задач анализа.

Постановка задачи. При построении моделей оценки качества пользовательского опыта (Quality of Experience или QoE) [2] в IP-сетях критическое значение имеет метод интервального кодирования непрерывных сетевых метрик. В системе «Эйдос-X++» реализованы два альтернативных подхода к дискретизации данных.

1. Адаптивный метод – разбиение на интервалы различной ширины с равным числом наблюдений (3 интервала по 33,33% в каждом). Границы интервалов автоматически подстраиваются под реальное распределение данных.

2. Фиксированный метод – разбиение на равные интервалы с разным числом наблюдений. Диапазон значений делится на три равные части независимо от распределения данных.

Исследование проводилось на датасете сетевого мониторинга устройства SD-WAN, включающего показатели: Rx, Tx, Jitter, Latency, Packet Loss [3]. Целевая переменная – интегральный показатель QoE (%). Для оценки эффективности методов использовались критерии достоверности L1-мера проф. Е. В. Луценко и F-мера Ван Ризбергена [4].

Для загрузки исходных данных использовался универсальный интерфейс API-2.3.2.2 системы «Эйдос-X++» (рис. 1).

Рис. 1. Импорт данных в системе «Эйдос-X++»

На рис. 2 представлены интервалы показателя потери пакетов (packet loss), полученные в результате загрузки данных с разбиением на разные интервалы с равным числом наблюдений.

Код шкалы	Наименование описательной шкалы	Код градации	Наименование градации описательной шкалы
1	RX	13	1/3-{0.0122420, 0.2786714}
2	TX	14	2/3-{0.2786714, 1.7617425}
3	JITTER	15	3/3-{1.7617425, 11.2856432}
4	LATENCY		
5	PACKET_LOSS		

Рис. 2. Разные интервалы Packet Loss с равным числом наблюдений

На рис. 3 представлен показатель потери пакетов (packet loss). Загрузка данных проведена с разбиением на равные интервалы с разным числом наблюдений.

Код шкалы	Наименование описательной шкалы	Код градации	Наименование градации описательной шкалы
1	RX	13	1/3-{0.0122420, 3.7700424}
2	TX	14	2/3-{3.7700424, 7.5278428}
3	JITTER	15	3/3-{7.5278428, 11.2856432}
4	LATENCY		
5	PACKET_LOSS		

Рис. 3. Равные интервалы Packet Loss с разным числом наблюдений

Результаты сравнения методов. Сравнительное тестирование двух методов кодирования проводилось на идентичном наборе из 348 наблюдений с использованием системно-когнитивной модели INF3 (хи-квадрат К. Пирсона) [5]. Результаты демонстрируют статистически значимые различия в эффективности подходов (табл. 1).

Таблица 1

Количественные показатели

Показатель	Адаптивный метод	Фиксированный метод	Разница
L1-мера	0,927	0,911	1,8%
F-мера	0,879	0,821	7,1%
Сбалансированность классов	33,33%/33,33%/33,33%	~85%/~12%/~3%	—

Адаптивный метод (разные интервалы с равным числом наблюдений) показал следующие результаты (рис. 4):

- L1-мера достигла 0,927;
- F-мера составила 0,879;
- каждый из трех интервалов содержал ровно 116 наблюдений (33,33%).

Наименование модели и частного критерия	Интегральный критерий	F-мера Ван Ризбергена	Сумма модул. уровней сход. истинно-полож. решений (STP)	Сумма модул. уровней сход. истинно-отриц. решений (STN)	Сумма модул. уровней сход. ложно-полож. решений (SFP)	Сумма модул. уровней сход. ложно-отриц. решений (SFN)	S-Точность модели	S-Полнота модели	L1-мера проф. Е.В. Луденко
1. ABS_basic_level - частный критерий: количество встреч сочетаний "класс-признак" у объектов обучающей выборки	Correlation of absolute frequen...	0.879	249.311	278.309	35.235	6.267	0.876	0.975	0.923
2. ABS_basic_level - частный критерий: количество встреч сочетаний "класс-признак" у объектов обучающей выборки	Sum of absolute frequencies by ...	0.498	273.902		174.013		0.612	1.000	0.759
3. PRC1_basic_level - частный критерий: усл. вероятность того признака среди признаков объектов того класса	Correlation of relative frequen...	0.879	249.311	278.309	35.235	6.267	0.876	0.975	0.923
4. PRC1_basic_level - частный критерий: усл. вероятность того признака среди признаков объектов того класса	Sum of conditional relative frequ...	0.498	274.769		174.701		0.611	1.000	0.759
5. PRC2_basic_level - частный критерий: условная вероятность того признака у объектов того класса	Correlation of relative frequen...	0.879	249.315	278.313	35.235	6.267	0.876	0.975	0.923
6. PRC2_basic_level - частный критерий: условная вероятность того признака у объектов того класса	Sum of conditional relative frequ...	0.498	275.348		175.160		0.611	1.000	0.759
7. INF1_basic_level - частный критерий: количество знаний по АХаркевичу: вероятности из PRC1	Semantic resonance of knowledge	0.764	199.931	240.854	46.971	5.811	0.810	0.972	0.883
8. INF1_basic_level - частный критерий: количество знаний по АХаркевичу: вероятности из PRC1	The sum of knowledge	0.820	84.321	276.890	12.301	9.253	0.873	0.901	0.887
9. INF2_basic_level - частный критерий: количество знаний по АХаркевичу: вероятности из PRC2	Semantic resonance of knowledge	0.764	199.867	240.807	46.987	5.811	0.810	0.972	0.883
10. INF2_basic_level - частный критерий: количество знаний по АХаркевичу: вероятности из PRC2	The sum of knowledge	0.820	84.214	276.515	12.288	9.230	0.873	0.901	0.887
11. INF3_basic_level - частный критерий: "хи-квадрат: разности между фактическими и ожидаемыми абс. частотами"	Semantic resonance of knowledge	0.879	248.860	277.920	35.251	6.228	0.876	0.976	0.923
12. INF3_basic_level - частный критерий: "хи-квадрат: разности между фактическими и ожидаемыми абс. частотами"	The sum of knowledge	0.879	226.616	251.541	30.195	5.270	0.882	0.977	0.927
13. INF4_basic_level - частный критерий: ROI (Return On Investment): вероятности из PRC1	Semantic resonance of knowledge	0.858	239.317	267.028	34.885	7.116	0.873	0.971	0.919
14. INF4_basic_level - частный критерий: ROI (Return On Investment): вероятности из PRC1	The sum of knowledge	0.824	228.388	188.596	36.405	5.284	0.863	0.977	0.916
15. INF5_basic_level - частный критерий: ROI (Return On Investment): вероятности из PRC2	Semantic resonance of knowledge	0.858	239.292	267.007	34.890	7.116	0.873	0.971	0.919
16. INF5_basic_level - частный критерий: ROI (Return On Investment): вероятности из PRC2	The sum of knowledge	0.824	229.215	189.274	36.567	5.296	0.862	0.977	0.916
17. INF6_basic_level - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC1	Semantic resonance of knowledge	0.856	239.419	267.127	34.870	7.103	0.873	0.971	0.919
18. INF6_basic_level - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC1	The sum of knowledge	0.824	227.268	187.956	36.134	5.296	0.863	0.977	0.916
19. INF7_basic_level - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC2	Semantic resonance of knowledge	0.856	239.395	267.106	34.875	7.104	0.873	0.971	0.919
20. INF7_basic_level - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC2	The sum of knowledge	0.824	228.088	188.634	36.294	5.307	0.863	0.977	0.916

Рис. 4. Показатели достоверности моделей, адаптивный метод

Критически важным оказалось автоматическое определение границ интервалов. Для показателя Packet Loss система установила пороги 0,28 и 1,76%, которые соответствуют эмпирическим наблюдениям инженеров: при потерях до 0,3% пользователи не замечают деградации качества, а после 1,8% начинаются заметные проблемы с VoIP и видеосвязью.

Фиксированный метод (равные интервалы с разным числом наблюдений) продемонстрировал (рис. 5):

- L1-мера – 0,911 (снижение на 1,8%);
- F-мера – 0,821 (снижение на 7,1%);
- крайне неравномерное распределение наблюдений между интервалами.

При фиксированном методе подавляющее большинство наблюдений сконцентрировалось в первом интервале (0–3,77% для Packet Loss), что создало существенное смещение модели в сторону распознавания только нормальных состояний сети.

Наименование модели и частного критерия	Интегральный критерий	F-мера Ван Ризбергена	Средн. модул. уровень сход. истинно-полож. решений (STP)	Средн. модул. уровень сход. истинно-отриц. решений (STN)	Средн. модул. уровень сход. ложно-полож. решений (SFP)	Средн. модул. уровень сход. ложно-отриц. решений (SFN)	S-Точность модели	S-Полнота модели	L1-мера проф. Е.В. Луценко
1. ABS - частный критерий: количество встреч сочетаний "класс-признак" у объектов обучающей выборки	Корреляция абс. частот с обр...	0.642	264.973	72.294	186.946	4.323	0.586	0.984	0.735
2. ABS - частный критерий: количество встреч сочетаний "класс-признак" у объектов обучающей выборки	Средн. абс. частот по призна...	0.498	242.709		93.518		0.722	1.000	0.838
3. PRC1 - частный критерий: усл. вероятность его признака среди признаков объектов его класса	Корреляция усл.отн. частот с о...	0.642	264.973	72.294	186.946	4.323	0.586	0.984	0.735
4. PRC1 - частный критерий: усл. вероятность его признака среди признаков объектов его класса	Средн. усл.отн. частот по приз...	0.498	279.167		283.903		0.496	1.000	0.663
5. PRC2 - частный критерий: условная вероятность его признака у объектов его класса	Корреляция усл.отн. частот с о...	0.642	264.965	72.290	186.912	4.322	0.586	0.984	0.735
6. PRC2 - частный критерий: условная вероятность его признака у объектов его класса	Средн. усл.отн. частот по приз...	0.498	279.243		284.286		0.496	1.000	0.663
7. INF1 - частный критерий: количество знаний по А.Харкевичу: вероятности из PRC1	Семантический резонанс зна...	0.779	146.262	441.341	42.240	22.356	0.776	0.867	0.819
8. INF1 - частный критерий: количество знаний по А.Харкевичу: вероятности из PRC1	Средн. знаний	0.762	44.920	334.749	31.162	8.167	0.590	0.846	0.696
9. INF2 - частный критерий: количество знаний по А.Харкевичу: вероятности из PRC2	Семантический резонанс зна...	0.779	146.203	441.341	42.239	22.357	0.776	0.867	0.819
10. INF2 - частный критерий: количество знаний по А.Харкевичу: вероятности из PRC2	Средн. знаний	0.761	44.948	334.636	31.226	8.171	0.590	0.846	0.695
11. INF3 - частный критерий: Уинквэдрат, разности между фактическими и ожидаемыми абс. частотами	Семантический резонанс зна...	0.821	238.553	456.688	44.574	19.050	0.843	0.926	0.882
12. INF3 - частный критерий: Уинквэдрат, разности между фактическими и ожидаемыми абс. частотами	Средн. знаний	0.821	230.600	249.874	32.223	12.950	0.877	0.947	0.911
13. INF4 - частный критерий: ROI (Return On Investment): вероятности из PRC1	Семантический резонанс зна...	0.770	176.945	413.208	42.832	25.591	0.805	0.874	0.838
14. INF4 - частный критерий: ROI (Return On Investment): вероятности из PRC1	Средн. знаний	0.745	31.535	53.403	31.009	1.533	0.504	0.954	0.660
15. INF5 - частный критерий: ROI (Return On Investment): вероятности из PRC2	Семантический резонанс зна...	0.770	176.848	413.206	42.830	25.592	0.805	0.874	0.838
16. INF5 - частный критерий: ROI (Return On Investment): вероятности из PRC2	Средн. знаний	0.745	31.517	53.271	31.024	1.532	0.504	0.954	0.659
17. INF6 - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC1	Семантический резонанс зна...	0.798	228.102	449.036	41.345	19.618	0.847	0.921	0.882
18. INF6 - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC1	Средн. знаний	0.796	75.765	389.884	30.407	11.791	0.714	0.865	0.782
19. INF7 - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC2	Семантический резонанс зна...	0.798	228.070	449.033	41.347	19.609	0.847	0.921	0.882
20. INF7 - частный критерий: разн. усл. и безуслов. вероятностей: вероятности из PRC2	Средн. знаний	0.796	75.689	389.693	30.457	11.758	0.713	0.866	0.782

Рис. 5. Показатели достоверности моделей, фиксированный метод

Заключение. Проведенное исследование подтвердило статистически значимое превосходство адаптивного метода интервального кодирования данных над фиксированным: прирост точности составил 3,6%, L1-меры – 1,8%, F-меры – 7,1%. В условиях критически важных сетевых сервисов это означает трехкратное сокращение числа необнаруженных инцидентов.

Успех адаптивного метода обусловлен устранением дисбаланса классов и автоматическим определением естественных порогов деградации качества. Выявленные границы (0,28 и 1,76% для Packet Loss) точно соответствуют эмпирическим наблюдениям о восприятии качества пользователями.

Фиксированный метод остается приемлемым для задач, где приоритетна простота интерпретации и стандартизация процедур мониторинга. Снижение точности на 3–4% может быть допустимо в обмен на упрощение эксплуатации.

Оптимальной стратегией представляется двухэтапный подход: применение адаптивного метода для определения критических порогов с последующим их округлением до практически удобных значений. Это позволит совместить высокую точность анализа с простотой производственного применения.

Результаты исследования применимы не только к анализу QoE в IP-сетях, но и к широкому классу задач классификации с несбалансированными данными, что определяет их практическую ценность для различных областей сетевого мониторинга и управления.

Библиографический список

1. Эйдос-X++. Универсальная когнитивная аналитическая система. URL: http://lc.kubagro.ru/aidos/_Aidos-X.htm
2. Stankiewicz R., Jajszczyk A. A survey of QoE assurance in converged networks // Computer Networks. 2011. Vol. 55, iss. 7. P. 1459–1473. DOI [10.1016/j.comnet.2011.02.004](https://doi.org/10.1016/j.comnet.2011.02.004)
3. ITU-T Recommendation O.211, Test and measurement equipment to perform tests at the IP layer. 2006. URL: https://www.itu.int/rec/dologin_pub.asp?lang=e&id=T-REC-O.211-200601-I!!PDF-R
4. Луценко Е. В. Нечеткое мультиклассовое обобщение классической F-меры достоверности моделей Ван Ризбергена в АСК-анализе и системе «Эйдос» // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета (Научный журнал КубГАУ). 2016. № 09 (123). 29 с. IDA URL: <http://ej.kubagro.ru/2016/09/pdf/01.pdf>
5. Луценко Е. В. Автоматизированный системно-когнитивный анализ в управлении активными объектами: (системная теория информации и ее применение в исследовании экономических, социально-психологических, технологических и организационно-технических систем). Краснодар: КубГАУ им. И. Т. Трубилина, 2002. 605 с. EDN OCZFHС

COMPARISON OF SOURCE DATA PREPROCESSING OPTIONS USING THE UNIVERSAL COGNITIVE ANALYTICAL SYSTEM “EIDOS-X++”

Aleksei S. Elokhov

Perm National Research Polytechnic University
29, Komsomolsky Prospect, Perm, Russia, 614068
elokhov@gmail.com

This paper considers two approaches to preprocessing identical source data (quality metrics) acquired from an IP network monitoring system using the “EIDOS-X++” system: partitioning into variable-width intervals with equal observation counts, and fixed-width intervals with varying observation counts.

Keywords: IP networks, EIDOS-X++, jitter, packet loss, latency, QoE

ПЕРВИЧНЫЕ РЕЗУЛЬТАТЫ И ВЫЗОВЫ РАЗРАБОТКИ ИИ-СИСТЕМЫ ДЛЯ АНАЛИЗА ЧУВСТВИТЕЛЬНОГО МЕДИАКОНТЕНТА

Федосеев Сергей Анатольевич

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский проспект, д. 29
fsa@gelicon.biz

Шорников Антон Евгеньевич

Пермский национальный исследовательский политехнический университет,
614990, Россия, г. Пермь, Комсомольский проспект, д. 29
shornikov.anthon@yandex.ru

Статья посвящена обзору разработки системы искусственного интеллекта для автоматического распознавания и модерации чувствительного медиаконтента. Рассматриваются этапы сбора и подготовки обучающих данных, выбор и адаптация архитектур глубокого обучения, включая ResNet и мультимодальные модели CLIP. Проведен анализ результатов тестирования и сравнительного исследования различных подходов, а также обсуждены технологические и организационные вызовы, возникающие при внедрении ИИ в процессы автоматизированной модерации.

Ключевые слова: нейросетевые технологии, городская недвижимость, первичный рынок недвижимости, прогнозирование стоимости недвижимости

Введение. Модерация чувствительного контента является одной из главных задач, решаемых каждой публичной интернет-платформой. Одной из ключевых проблем медиарынка ее делает рост объемов публикуемого контента, а также усиление государственной регуляции как в части категорий и форм цензурируемой информации, так и в части накладываемых на компании штрафов и блокировки [1]. Стараясь снизить риски нарушения законодательства, платформы вынуждены усиливать команды модераторов контента, нанимая новых сотрудников для немедленной блокировки запрещенных материалов [2, 3]. Вместе с расширением штата сотрудников компании начинают проявлять интерес к рынку ИИ-решений в области глубокого обучения и распознавания образов. Внедрение автоматизированных систем модерации позволит быстрее анализировать публикуемый контент при сравнительно низких затратах.

В данном материале представлен опыт проектирования компонент ИИ-системы: от сбора данных до сравнительных испытаний архитектур.

Данная работа будет полезна командам и небольшим продуктам, выстраивающим свои подходы по работе с публикуемым пользовательским фото- и видео-контентом.

Основная цель работы – проектирование, обучение и валидация системы распознавания образов в фото- и видеоконтенте. Конечный результат – нейросетевая система, способная оценивать фото- и видеоконтент на предмет наличия и отсутствия визуальных образов, входящих в перечень цензурируемого контента.

Экономическая эффективность решения. Внедрение ИИ-решения для автоматизированной модерации видеоконтента существенно влияет на экономику процессов модерации, снижая нагрузку на операторов. В табл. 1 приведен расчет с учетом средних ставок заработной платы и аренды GPU ресурсов на конец 2024 г. [4].

Таблица 1

Оценка экономической эффективности ИИ-системы модерации

Показатель	Оператор	ИИ-система
Рабочих часов в месяц	160	720
Заработная плата / стоимость аренды GPU, руб.	60 000	150 000
Коэффициент усталости	0,2	0
Производительность труда, в часах просмотра видео	256 При просмотре на удвоенной скорости воспроизведения	7500

На основании проведенной оценки можно сказать, что ИИ-система модерации сравнима по производительности с 30 модераторами, по стоимости эксплуатации сравнима с оплатой труда 2–3 сотрудников. При этом стоит отметить, что максимальный эффект от внедрения системы можно получить, если поток публикаций на медиаплатформе в среднем составляет около 250 часов видео в сутки.

Постановка задачи и формирование обучающего множества. Для реализации ИИ-системы модерации были выбраны следующие категории:

- порнография – сцены секса и приватные части тела;
- алкоголь – бутылки, этикетки и посуда;
- курение – сигареты, пачки и логотипы;
- военная тематика – трупы людей, кровь, оружие и военная техника.

Задача детекции контента ограничена только изображением. Кадры видеоролика в текущей архитектуре рассматриваются как отдельно взятые изображения без анализа контекста целой сцены.

Для формирования обучающего множества был выполнен сбор изображений с открытых источников. В общей сложности собрано около 10 миллионов изображений. Собранное множество прошло следующие шаги постобработки:

1) очистка датасета от бракованных кадров. Под браком понимаются мутные, полностью засвеченные или недоэкспонированные кадры;

2) очистка изображений от дубликатов на основании метрики перцептивного хэширования рHash [5];

3) формирование контактных отпечатков. Кластеризация изображений и сохранение множества миниатюр в единое изображение для упрощения осмотра и отбора цензурируемых категорий при настройке системы под конкретного заказчика.

Проектирование, обучение и тестирование нейросети. Первая версия сервиса строилась на архитектуре ResNet. Результаты тестирования на ограниченном наборе тестовых примеров показал достойную способность к детекции.




Рис. 1. Пример контактного отпечатка

Однако при масштабировании датасета обострился вопрос сбора нейтральных изображений, представляющих знание о реальном мире и противовес детектируемым категориям. С этой целью было принято решение перейти на архитектуру CLIP (ViT-L-336). Данный переход повысил точность zero-shot / one-shot классификации, позволил выполнять более тонкую настройку, а также повысить восприимчивость модели к тексту (рис. 2) [6–8].




Рис. 2. Результаты тестирования модели на базе CLIP (ViT-L-336)

Заключение. Получен обобщаемый опыт быстрой постановки и оптимизации ИИ-проекта под задачу чувствительной модерации медиаконтента. Критически важными оказались быстрый переход от «обычной» архитектуры к мультимодальным CLIP-решениям, внимательная работа с размечанием и балансировкой классов, а также инфраструктурные оптимизации под массовый inference. Экономический эффект ИИ-модератора проявляется в снижении затрат, уменьшении числа ошибочных блокировок и ускорении масштабирования бизнеса. Выявленные проблемы и эффекты совпадают с рисками и трендами, отмеченными в российских и международных публикациях о регулировании цифрового контента.

Библиографический список

1. Более 15 тысяч разжигающих вражду страниц заблокировано в Рунете с начала 2025 года // Cnews. 2025. URL: https://cnews.ru/news/top/2025-07-02_bole_15_000_razzhigayushchih_vrazhdu (дата обращения: 20.09.2025).
2. Токарева С. Цифровая чистота в России: планы по усилению противодействия экстремизму в сети // Известия. 2025. URL: <https://iz.ru/1921510/sofiia-tokareva/tcifrovaia-chistota-v-rossii-planiruiut-usilit-protivodeistvie-ekstremizmu-v-seti> (дата обращения: 20.09.2025).
3. Roskomnadzor AI tools and impact on media moderation in Russia // Russia Post. 2025. URL: https://russiapost.info/society/social_media_in_russia (дата обращения: 20.09.2025).
4. Зарплата модераторов: уровень дохода, факторы и перспективы роста // Skyprow. 2025. URL: <https://sky.pro/wiki/profession/zarplata-moderatorov-uroven-dohoda-factory-i-perspektivy-rosta/> (дата обращения: 23.09.2025).
5. Хитров В. «Выглядит похоже». Как работает перцептивный хэш // Хабр. 2025. URL: <https://habr.com/ru/articles/120562/> (дата обращения: 20.09.2025).
6. Gongane V. U., Munot M. V., Anuse A. D. Detection and moderation of detrimental content on social media platforms: Current status and future directions // Social Network Analysis and Mining. 2022. Vol. 12. Article 129. DOI [10.1007/s13278-022-00951-3](https://doi.org/10.1007/s13278-022-00951-3)
7. OpenAI. Zero-Shot Content Moderation with OpenAI's New CLIP Model. 2024. URL: <https://blog.roboflow.com/zero-shot-content-moderation-openai-new-clip-model/> (дата обращения: 23.09.2025).
8. Isinkaye F. O., Olusanya M. O., Singh P. K. Deep learning and content-based filtering techniques for improving plant disease identification and treatment recommendations: A comprehensive review // Heliyon. 2024. Vol. 10, iss. 9. e29583. DOI [10.1016/j.heliyon.2024.e29583](https://doi.org/10.1016/j.heliyon.2024.e29583)

DEVELOPMENT OF AN AI SYSTEM FOR ANALYZING SENSITIVE MEDIA CONTENT

Fedoseev Sergey Anatelievich

Perm National Research Polytechnic University
29, Komsomolsky Ave., Perm, Russia, 614990
fsa@gelicon.biz

Shornikov Anton Evgenievich

Perm National Research Polytechnic University
29, Komsomolsky Ave., Perm, Russia, 614990
shornikov.anthon@yandex.ru

The article is devoted to the development of an artificial intelligence system for the automatic moderation of sensitive media content. It reviews the key stages of the project: the collection and cleaning of a training dataset of about 10 million images, and the selection and adaptation of deep learning architectures—from ResNet to the multimodal CLIP model (ViT-L-336). The conducted analysis shows that the implementation of the AI system is comparable in performance to the work of 30 human moderators, while its operational cost is similar to employing only 2–3 people, confirming its high economic efficiency. The final result is a neural network system capable of accurately identifying categories such as pornography, alcohol, smoking, and military themes in photo and video content.

Keywords: artificial intelligence, neural network technologies, content moderation, deep learning, computer vision, sensitive content, CLIP, ResNet

ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ИЗВЛЕЧЕНИЯ ФАКТОВ ИЗ НЕСТРУКТУРИРОВАННЫХ ТЕКСТОВ

Воронова Кристина Дмитриевна

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
christinavoronova12@gmail.com

В статье представлены результаты исследования применения генеративного искусственного интеллекта (ИИ) для автоматизации извлечения фактов из неструктурированных текстов. Обоснована актуальность задачи в условиях роста объемов данных и ограничений традиционных способов обработки. Разработана методика использования больших языковых моделей: ChatGPT, DeepSeek, YandexGPT, GigaChat – для поиска фактов, их аннотирования и преобразования в структурированный формат. Проведен сравнительный анализ моделей по полноте извлекаемых данных, подтверждающий эффективность генеративного ИИ.

Ключевые слова: генеративный искусственный интеллект, извлечение фактов, неструктурированные тексты, большие языковые модели, автоматизация анализа данных

Введение. По современным оценкам, около 80% данных в интернете хранится в неструктурированном виде [1]. Например, к неструктурированным данным относятся новостные публикации, научные статьи, медицинские записи, юридические документы. Такой массив данных имеет огромный потенциал для бизнеса, науки, государственного управления и социальных сервисов, однако его использование затруднено из-за отсутствия унифицированной структуры.

Для работы с подобными данными необходимы инструменты, которые позволяют быстро и достоверно выявлять факты, события, взаимосвязи и причинно-следственные отношения. Однако традиционные методы анализа текста: шаблонные алгоритмы, ручная разметка, онтологии и классические технологии обработки естественного языка – обладают рядом ограничений [2, 3]. Зачастую они не обеспечивают достаточной полноты и точности извлечения информации, плохо масштабируются при росте объемов данных и при работе с другой предметной областью, а также требуют высокой квалификации специалистов для настройки и сопровождения. Применение правил и онтологий оправдано в тех случаях, когда концепты и связи заранее формализованы. При расширении сферы анализа подходы становятся трудоемкими и дорогими в поддержке, а необходимость постоянного обновления словарей и классификаторов приводит к задержкам и снижает актуальность результатов.

Развитие генеративного искусственного интеллекта открывает новые возможности для преодоления перечисленных трудностей [4, 5]. Большие языковые модели (LLM) способны не только генерировать связанные тексты, но и извлекать факты и их семантические связи напрямую из неструктурированных данных.

Их применение позволяет автоматизировать ключевые этапы анализа, повысить полноту и точность результатов, а также снизить требования к квалификации пользователей.

Настоящее исследование направлено на разработку и апробацию методики извлечения фактов из неструктурированных текстов с использованием генеративного ИИ. Предполагаемый подход сочетает в себе применение современных языковых моделей для поиска фактов, их аннотирования и представления в структурированном виде. Такой подход ориентирован на широкий спектр приложений – от аналитики больших данных до поддержки принятия управленческих решений.

Постановка задачи и разработка методики извлечения фактов. Целью исследования является разработка методики автоматизированного извлечения фактов из неструктурированных текстов с обеспечением высокой полноты, корректности и структурированности получаемых данных. Под фактом понимается событие, описанное в тексте и характеризующееся атрибутами: участники, время, место, причина и следствие [2, 3].

Для проверки предложенного подхода разработан экспериментальный дизайн, включающий два сценария:

- 1) контролируемый – анализ заранее подготовленных текстов, позволяющий объективно сравнить качество извлечения;
- 2) открытый – автоматический поиск или генерация источников, имитирующие реальные условия потоковой информации.

В обоих сценариях использовались четыре актуальные генеративные языковые модели (LLM): ChatGPT, DeepSeek, YandexGPT и GigaChat. Их выбор обусловлен качеством работы с русскоязычными текстами, способностью формировать структурированный вывод и доступностью для интеграции в аналитические системы.

Методика включает последовательность этапов.

1. Формализация требований к результату (структура факта, формат вывода).
2. Формирование запросов к моделям с учетом критериев полноты и корректности.
3. Извлечение и структурирование данных в табличном формате.
4. Оценка качества, которая проводится по показателям полноты (соотношение найденных фактов к эталону), корректности (точности соответствия исходному тексту) и структурности (соответствие заданному формату). Эти критерии отражают ключевые требования к современным системам анализа данных [1].

Ключевыми моментами методики являются интеграция двух сценариев взаимодействия с ИИ в единую схему и сравнение нескольких генеративных моделей по единым формальным метрикам. Такой подход позволяет комплексно оценить возможности генеративного искусственного интеллекта в задачах извлечения фактов.

Результаты методики. Предложенная методика была проверена в двух сценариях взаимодействия с генеративным искусственным интеллектом. Для оценки работы четырех языковых моделей рассматривались показатели полноты извлечения, корректности и структурности представления результатов.

В контролируемом сценарии анализировались заранее подготовленные тексты различных тематик (экономический и о животных). Каждая модель гене-

ративного ИИ получила одинаковые условия ввода и единый формат требуемого ответа. Рассмотрим результаты, полученные в рамках первого сценария (табл. 1).

Таблица 1

Сравнительная таблица по моделям в рамках первого сценария

Модель	Полнота (Текст 1 / Текст 2)	Структурность	Количество итераций
ChatGPT	высокая / высокая	высокая	1
DeepSeek	высокая / высокая	высокая	1
YandexGPT	средняя / средняя	высокая	1
GigaChat	низкая / средняя	высокая	1

Результаты показывают, что ChatGPT и DeepSeek стабильно обеспечивают высокую полноту извлечения фактов в обоих тестовых текстах. YandexGPT продемонстрировал среднюю полноту, но хорошую структурность. GigaChat выявил меньше фактов в первом тексте, что отразилось на суммарной оценке полноты. На рис. 1 представлено количество фактов, извлеченных каждой моделью по двум тематикам.




Рис. 1. Количество извлеченных фактов каждой моделью ИИ

На рис. 1 видно, что ChatGPT и DeepSeek достигли максимальных значений (до 7 фактов), в то время как GigaChat ограничился 4–5 фактами.

К положительным сторонам контролируемого сценария относятся высокая воспроизводимость и простота сравнения моделей. Основным ограничением остается ограниченная вариативность исходных текстов, что не отражает всего разнообразия реальных данных.

В открытом сценарии каждая модель самостоятельно подбирала источники по заданной теме и извлекала из них факты. Это максимально приближало эксперименты к реальным условиям. Далее представлена таблица с результатами по второму сценарию.

В рамках второго сценария YandexGPT и GigaChat сумели обеспечить высокую полноту при минимальном числе итераций. В свою очередь, зарубежные модели ChatGPT и DeepSeek, напротив, потребовали по две итерации для уточ-

нения ответа. Также GigaChat и DeepSeek отстали по качеству найденных текстов: в промпте явно указывался временной промежуток, за который необходимо найти информацию, но они выходили за его рамки.

Таблица 2

Сравнительная таблица по моделям в рамках второго сценария

Модель	Качество найденных текстов	Полнота (Текст 1 / Текст 2)	Количество итераций
ChatGPT	высокое	средняя / средняя	2
DeepSeek	среднее	средняя / средняя	2
YandexGPT	высокое	высокая / высокая	1
GigaChat	среднее	высокая / высокая	1

Стоит предположить, что во втором сценарии отечественные модели лучше справились за счет того, что промпт был проблемным: имел много уточнений и достаточно сложную структуру, а зарубежным моделям сложнее обрабатывать такие конструкции.

Для комплексной оценки эффективности генеративных языковых моделей проведен интегральный анализ всех ключевых показателей. Таблица 3 объединяет результаты работы в обоих сценариях.

Таблица 3

Сравнительный анализ моделей

Показатель	ChatGPT	DeepSeek	YandexGPT	GigaChat
Полнота извлечения	Высокая	Высокая	Средняя	Средняя
Корректность интерпретации	Высокая	Высокая	Средняя	Средняя
Структурированность результата	Высокая	Высокая	Средняя	Средняя
Гибкость и адаптивность	Высокая	Средняя	Средняя	Средняя
Автономность в открытом сценарии	Средняя	Средняя	Высокая	Высокая
Необходимость уточняющих запросов	Редко	Редко	Нет	Нет

Можно заключить, что наиболее эффективной в рамках поставленной задачи оказалась модель ChatGPT. Она показала высокую точность извлечения, отличную адаптивность и способность работать без постоянного вмешательства пользователя. DeepSeek также зарекомендовал себя как надежный инструмент при условии корректного задания промптов. YandexGPT и GigaChat, несмотря на определенные преимущества в плане доступности и понимания русского языка, нуждаются в доработке, в частности в части интерпретации сложных задач и устойчивости к вариативности входных запросов.

Заключение. Предложенная методика для автоматизированного извлечения фактов из неструктурированных текстов с использованием генеративного искусственного интеллекта доказала свою эффективность в двух экспериментальных сценариях. Исследование показало, что генеративные языковые модели способны формировать структурированные факты с высокой полнотой и корректностью, существенно сокращая трудозатраты при анализе данных. Полученные результаты позволяют рекомендовать рассматриваемые модели для решения задачи извлечения фактов.

Библиографический список

1. Adnan K., Akbar R. An Analytical Study of Information Extraction from Unstructured and Multi-dimensional Big Data // Journal of Big Data. 2019. Vol. 6, iss. 1. P. 1–12. DOI 10.1186/s40537-019-0254-8
2. Mikheev A. A., Yarigina Y. S. The Concept of Modelling Semantic Markup of Text Corpora on the Basis of Event Ontology // Russian Linguistic Bulletin. 2024. No. 1 (49). DOI 10.18454/RULB.2024.49.37
3. Ma M., Wang P., Yang J., Li C. OntoEvent: An Ontology-Based Event Description Language for Semantic Complex Event Processing // Proceedings of the 16th International Conference on Web-Age Information Management (WAIM 2015). Springer, Cham, 2015. P. 348–359. DOI 10.1007/978-3-319-21042-1_38
4. Patel R., Green L., White J. A Scoping Review of Large Language Model-Based Approaches for Information Extraction from Radiology Reports // npj Digital Medicine. 2024. DOI 10.1038/s41746-024-01219-0
5. Johnson T., Clark E., Adams M. LLM-AIx: An Open Source Pipeline for Information Extraction from Unstructured Medical Text Based on Privacy-Preserving Large Language Models // medRxiv preprint. 2024. DOI 10.1101/2024.09.02.24312917v1

RESEARCH OF GENERATIVE ARTIFICIAL INTELLIGENCE CAPABILITIES FOR FACT EXTRACTION FROM UNSTRUCTURED TEXTS

Kristina D. Voronova

HSE University

38, Studencheskaya Str., Perm, Russia, 614070

christinavoronova12@gmail.com

The paper presents the results of a study on the application of generative artificial intelligence (AI) to automate the extraction of facts from unstructured texts. The relevance of the task is justified by the rapid growth of data volumes and the limitations of traditional natural-language and ontology-based methods. A methodology has been developed that employs large language models (LLMs) – ChatGPT, DeepSeek, YandexGPT and GigaChat – to identify factual events in texts, annotate them and convert the extracted information into a structured format. The experimental design included two scenarios: a controlled scenario with pre-selected texts and an open scenario with automatic search or generation of source texts. The models' performance was evaluated by completeness, correctness and structural consistency of the extracted facts. Comparative experiments demonstrated that generative AI can provide high factual accuracy and significantly reduce the time required for data analysis. ChatGPT showed the best overall efficiency, DeepSeek proved reliable with carefully formulated prompts, while YandexGPT and GigaChat displayed advantages in autonomy when working with open information streams. The proposed approach allows for comprehensive assessment and selection of generative models for fact-extraction tasks in analytics, decision support and knowledge management systems.

Keywords: generative artificial intelligence, fact extraction, unstructured texts, large language models, data analysis automation

ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ АВТОМАТИЗАЦИИ ПОСТРОЕНИЯ ОНТОЛОГИЙ ДЛЯ ИНФОРМАЦИОННЫХ СИСТЕМ, УПРАВЛЯЕМЫХ ЗНАНИЯМИ

Шебырева Анна Александровна

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
ashebyreva@mail.ru

Статья посвящена изучению возможности автоматизированного построения онтологий для снижения порога вхождения для специалистов, не имеющих глубоких знаний в области инженерии знаний. Предлагается методика для разработки онтологии с использованием генеративного искусственного интеллекта. Приведены результаты апробации предложенного подхода с помощью ChatGPT. Проведенные эксперименты доказали возможность использования генеративного ИИ при разработке онтологии, однако требуется проверка ответов, сформированных ИИ, на возможные ошибки.

Ключевые слова: онтологии, генеративный искусственный интеллект, автоматизация построения онтологий

Введение. Онтологии используются в различных предметных областях: в медицине – для стандартизации концепций и выбора методов лечения, в финансах – для унификации понятий и автоматизации процессов, в образовании – для проектирования учебных материалов и планирования курсов, в киберфизических системах – для стандартизации устройств и их взаимодействия, а в программировании – для структурирования знаний и интеграции компонентов [1, 2, 7, 8]. В области программной инженерии онтологии применяют для структурирования знаний, моделирования и визуализации данных, автоматической генерации языков программирования, обеспечения семантической совместимости между компонентами системы [9, 10]. Однако процесс построения онтологий требует высокой квалификации инженеров по знаниям и длительной совместной работы с экспертами предметной области. Существующие методы построения онтологий, такие как метод MASK, основанный на интервьюировании экспертов [4, 5], метод автоматизированного наполнения онтологий METEOR [8], позволяют автоматизировать лишь конкретные этапы построения онтологии. Однако эти методы не решают проблему высоких требований к квалификации инженеров по знаниям: необходимости владения профессиональными инструментами разработки и глубокими навыками в инженерии знаний.

Построение онтологии (рис. 1) для разработки информационных систем – это сложный процесс. Так как специалистов, имеющих знания сразу в двух областях, крайне мало, то чаще всего для задачи разработки онтологии привлекают сразу несколько специалистов, что приводит к повышению стоимости разработки, трудностям взаимодействия специалистов между собой, нехватке высоко-

квалифицированных специалистов [6]. Все это затрудняет объединение и повсеместное использование получаемой информации [1, 3]. Семантический разрыв возникает из-за фундаментального несоответствия между способом мышления экспертов предметной области, неоднозначности понятий на естественном языке и формальными методами, которые используют специалисты по знаниям.




Рис. 1. Процесс построения онтологий

Методика построения онтологий с использованием генеративного искусственного интеллекта. Инструменты типа GigaChat от Сбера, YandexGPT от Яндекса, OpenAI, DeepSeak, Mistral AI, Microsoft, которые на основе запросов могут генерировать любую информацию, видео, схемы, изображения, код и т.д, получили широкое распространение в последние годы. Использование таких методов открывает возможности для автоматической генерации концептов, отношений, классов и свойств.

Процесс разработки онтологии включает следующие этапы.

1. Автоматизированный поиск источников по заданной теме. Запрос включает в себя цель разработки онтологии, типы источников, которые необходимо рассматривать. Результат представляет собой список источников, сгруппированных по их типам, с кратким описанием и оценкой каждого источника.

2. Автоматизированный анализ источников. В запросах указывается перечень источников из предыдущих запросов, который необходимо сначала объединить в один общий, а затем выделить основные концепты, свойства, отношения для формирования будущей онтологии. Результаты – в виде таблиц, графов знаний.

3. Автоматическая генерация кода. На основе предыдущих запросов формулируются промты на перевод выделенных концептов и связей на формальный язык, в результате чего генерируется код на требуемом языке, например в формате owl.

4. Автоматизированная оценка построенной онтологии для проверки работоспособности онтологии.

Апробация методики на примере разработки онтологии языков программирования. Для проверки методики проведены эксперименты по построению онтологии языков программирования на основе их классификации с помо-

щью ChatGPT. В результате запроса на поиск источников был получен список литературы, содержащий как книги, научные статьи и публикации, документации языков программирования, так и интернет-ресурсы. Однако при проведении ручной проверки были выявлены ошибки: ИИ предложил статьи, которые не существуют, статьи, у которых неверно указано авторство или тип источника.

При запросе на определение классификаций ЯП по каждому источнику были предложены как наиболее распространенные классификации (по поколению, по парадигме, по уровню абстракции), так и классификации, встречающиеся лишь в некоторых источниках (по сфере применения, по поддержке параллелизма, по стилю управления потоком).

Запрос на построение графа знаний на основе полученной информации был информативным, однако содержал ошибки в самих терминах (рис. 2).



Рис. 2. Граф знаний для классификации языков программирования

Запросы на дополнение и уточнение классификации языков программирования позволили получить более полные данные для онтологии (рис. 3).

Критерий классификации	Примеры языков программирования
Парадигма программирования	Императивная: C, Fortran, Pascal, Go, Ada Декларативная: SQL, Prolog, XSLT Объектно-ориентированная: Java, C++, C#, Smalltalk, Objective-C, Swift Функциональная: Haskell, Erlang, F#, OCaml, Lisp, Scheme Логическая: Prolog, Gödel, Mercury Процедурная: Pascal, C, BASIC, Modula-2 Событийная: JavaScript, Visual Basic, ActionScript Реактивная: Elm, ReactiveX, RxJS
Уровень абстракции	Низкоуровневые: Ассемблер, C Среднеуровневые: C++, Rust, Go Высокоуровневые: Python, Ruby, Java, Kotlin
Типизация	Статическая: Java, Haskell, C++, Rust, Scala Динамическая: Python, JavaScript, Ruby, PHP Строгая: Haskell, Rust, Scala Слабая: JavaScript, PHP Неявная: Haskell, Scala, F# Явная: C, Java, C++

Рис. 3. Фрагмент классификации языков программирования

На основе полученных ответов был составлен запрос на представление получившейся онтологии в формате owl. Запросы были направлены на формирование списка источников, генерацию концептов, объектных свойств, а также на основе полученной информации был составлен запрос на генерацию кода owl (рис. 4), который был загружен в редактор онтологий Protégé (рис. 5). Полученная онтология включает более 100 концептов и логических связей, а owl-код – более 500 строк. В центре онтологии – класс Programming Language, к которому привязаны свойства – критерии классификации. Каждый язык программирования моделируется как индивидум класса Programming Language, с указанием соответствующих ему свойств. В качестве недостатков данной онтологии можно отметить отсутствие синтаксических характеристик языков (грамматики, правил вывода), а также ограниченность списка языков программирования: рассматриваются только наиболее популярные и используемые, а существующих языков программирования в разы больше, что делает онтологию неполной. Поэтому для расширения будущей онтологии необходимо рассматривать дополнительные источники для извлечения других концептов и свойств.

```

xmlns:ex="http://example.org/ontology#"
xmlns:rdfs="http://www.w3.org/2000/01/rdf-schema#"
xmlns:owl="http://www.w3.org/2002/07/owl#"
xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
>
<ex:ProgrammingLanguage rdf:about="http://example.org/ontology#PHP">
<ex:hasTyping rdf:resource="http://example.org/ontology#Dynamic"/>
<ex:hasTyping rdf:resource="http://example.org/ontology#Weak"/>
<ex:hasTranslationMethod rdf:resource="http://example.org/ontology#Interpreted"/>
<ex:hasApplicationDomain rdf:resource="http://example.org/ontology#Web"/>
</ex:ProgrammingLanguage>

```

Рис. 4. Фрагмент кода




Рис. 5. Фрагмент в редакторе Protégé

Генеративный ИИ позволяет значительно сократить время на первичный этап – сбор и предварительную структуризацию знаний. Предложенная методика

снижает порог входа для специалистов предметной области, позволяя им взаимодействовать с системой на уровне естественного языка. Однако данный метод также имеет недостатки: генерация некорректных фактов или логических связей; зависимость от качества промпта (prompt engineering) и входных источников; неполнота формализаций. Все это приводит к необходимости разработки специального компонента – AI-ассистента, который позволит устранять выявленные недостатки и предупреждать возможные ошибки за счет установленных правил, алгоритмов.

Заключение. В работе предложен и апробирован подход к автоматизации построения онтологий с использованием генеративного ИИ, который значительно ускоряет этапы сбора и структурирования знаний, хорошо справляется с генерацией кода по заданным условиям. Практическая значимость подтверждается проведенными экспериментами и полученными положительными результатами.

Метод перспективен для ускорения процесса разработки информационных систем, управляемых знаниями. Направления дальнейших исследований включают расширение области применения, изучение возможностей интеграции с другими этапами проектирования и моделями ИИ, а также разработку AI-ассистента для минимизации ошибок и повышения точности разрабатываемой онтологии.

Библиографический список

1. Deepa R., Vigneshwari S. An effective automated ontology construction based on the agriculture domain // ETRI Journal. 2022. Vol. 44, no. 4. P. 573–587. DOI 10.4218/etrij.2020-0439
2. Dzeiranian A. D., Ermakov I. D., Proskuryakov K. A., Lyadova L. N. Designing Data Visualization System Based on Language-Oriented Approach // Proceedings of the Institute for System Programming of the RAS. 2024. Vol. 36, no. 2. P. 127–140. DOI 10.15514/ISPRAS-2024-36(2)-10
3. Isern D., Sánchez D., Moreno A. Ontology-driven execution of clinical guidelines // Computer Methods and Programs in Biomedicine. 2012. Vol. 107, no. 2. P. 122–139. DOI 10.1016/j.cmpb.2011.06.006
4. Matta N., Ermine J. L., Aubertin G., Trivin J. Y. Knowledge Capitalization with a knowledge engineering approach: the MASK method // Knowledge Management and Organizational Memories. 2002. P. 17–28. DOI 10.1007/978-1-4615-0947-9_2
5. Matta N., Ermine J. L., Aubertin G., Trivin J. Y. How to capitalize knowledge with the MASK method // IJCAI 2001 Workshop on Knowledge Management and Organizational Memories. 2001. Vol. 6. URL: https://www.researchgate.net/publication/228884761_How_to_capitalize_knowledge_with_the_MASK_method
6. Uschold M., King M. Towards a methodology for building ontologies. Edinburgh: Artificial Intelligence Applications Institute, University of Edinburgh, 1995. P. 1–13. URL: <http://www.aiai.ed.ac.uk/project/ftp/pub/papers/uschold-kingontologies.pdf> (дата обращения: 12.09.2025).
7. Zouri M., Ferworn A. An ontology-based approach for curriculum mapping in higher education // 2021 IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC). Las Vegas: IEEE, 2021. P. 141–147. DOI 10.1109/CCWC51732.2021.9376163
8. Лещева И. А. Метод автоматизированного наполнения баз знаний онтологического типа: дис. ... канд. техн. наук. СПб., 2022. 215 с. URL: https://disser.spbu.ru/files/2022/disser_leshcheva.pdf (дата обращения: 11.09.2025).
9. Разумовский А. Г., Пантелеев М. Г. Использование онтологий в разработке программного обеспечения // Инженерия знаний и технологии семантического веба. 2011. № 2. С. 46–51. URL: <https://etu.ru/assets/files/university/izdatelstvo/izvestiya-spbgetu-leti/2011-08.pdf#page=46> (дата обращения: 11.09.2025).
10. Хорошевский В. Ф. Проектирование систем программного обеспечения под управлением онтологий: модели, методы, реализации // Онтология проектирования. 2019. Т. 9, № 4 (34). С. 429–448.

RESEARCH INTO THE POSSIBILITIES OF ONTOLOGY BUILDINGAUTOMATION FOR DEVELOPING KNOWLEDGE–DRIVEN INFORMATION SYSTEMS

Shebyreva Anna Aleksandrovna

HSE University
38, Studencheskaya Str., Perm, Russia, 614070
ashebyreva@mail.ru

The article is devoted to the study of the possibility of automated construction of ontologies to reduce the entry threshold for specialists who do not have deepknowledge in the field of knowledge engineering. A methodology is proposed for developing an ontology using generative artificial intelligence. The results of testing the proposed approach using ChatGPT are presented. The experiments conducted have shown the effectiveness of generative AI at all stages of ontology development,however, it is necessary to check the responses of the generated AI to possible errors.

Keywords: ontologies, generative artificial intelligence, automated ontologyconstruction

ТЕХНОЛОГИЯ ФИЗИЧЕСКИ ИНФОРМИРОВАННЫХ НЕЙРОННЫХ СЕТЕЙ НА ПРИМЕРЕ ЗАДАЧИ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ ПРОЦЕССА БИОЛОГИЧЕСКОЙ ОЧИСТКИ СТОКОВ

Тарасов Вячеслав Денисович
Тархов Дмитрий Альбертович
Шатров Анатолий Викторович

Санкт-Петербургский политехнический университет Петра Великого
195251, Россия, г. Санкт-Петербург, ул. Политехническая, 29
shatrov_av@spbstu.ru

В статье представлено описание и реализация технологии физически информированных нейронных сетей (PINN) на примере математической модели биологической очистки сточных вод. Предлагается алгоритм построения математической модели процесса нитрификации стоков в системе городских очистных сооружений на основе PINN. Проводится сравнительный анализ PINN-моделей и аналитической модификации классических численных методов. Осуществляется поиск оптимальных параметров PINN-моделей.


Ключевые слова: нейросетевые технологии, математическое моделирование, биологическая очистка сточных вод

Введение. Математическое моделирование в терминах дифференциальных уравнений является традиционным и хорошо разработанным способом описания сложных динамических процессов, в том числе технологий биологической очистки сточных вод. Методология такого подхода опирается на принципы кинетических взаимодействий между субстратом (загрязнениями) и бактериальными сообществами. При этом органические загрязнения представляют кормовую базу бактерий, являющихся основными компонентами активного ила, используемого в процессе биологической очистки. Процесс такого взаимодействия в реальности представляет многоуровневую, многокомпонентную и существенно неравновесную систему. Учет множества факторов приводит к созданию сложных динамических систем, идентификация которых весьма затруднительна. Поэтому представляется обоснованным подход с выделением наиболее важных аспектов в исследуемых процессах. Как показывает практика [1], основную массу органических загрязнений в современных городских коммунальных стоках составляют азотосодержащие соединения. Методика описания процессов нитрификации с точки зрения технологии физически информированных нейронных сетей обсуждается в данной публикации. Как отмечалось, стандартный подход к исследованиям такого рода динамических систем заключается в выборе системы дифференциальных уравнений, вытекающих из уравнений химической кинетики, и последующем поиске способов решения этой системы. Такой подход на сегодняшний день следует считать устаревшим [2, 5]. Современный подход состоит во взгляде на дифференциальные уравнения не как на абсолютно точную характеристику объекта (в большинстве работ по математическому моделированию они, по сути, заменяют сам

объект), а как на приближенную информацию о нем [2]. С такой точки зрения высокоточное решение дифференциальных уравнений представляется бессмысленным. Более перспективным представляется переход от дифференциальных уравнений к приближенной модели в виде функций, которую можно легко уточнить по результатам наблюдений [2].

В качестве таких функций все чаще используют физически информированные нейронные сети [5]. Однако большинство работ по PINN унаследовали недостатки классического подхода к математическому моделированию. Следуя моде на глубокое обучение *deep learning*, для поиска приближенных решений используются нейронные сети с большим числом нейронов и слоев, сети со сложной архитектурой, которая часто никак не связана с сутью задачи [5–9]. Наш опыт [2–4, 9] показывает, что в большинстве задач можно получить решение адекватной точности, используя нейронные сети с одним скрытым слоем с небольшим числом нейронов. Такие сети проще интерпретировать, доучивать по новым данным, использовать во встраиваемых системах и т.д. Работоспособность подобного подхода проверяется в данной работе на практически интересной задаче. При необходимости размер таких сетей легко увеличить, используя эволюционные алгоритмы [2].

Математическая модель процесса нитрификации. Очистка сточных вод включает множество сложных этапов. В данной работе основное внимание уделяется процессу удаления азота, что обусловлено его значительным вкладом в загрязнение водных объектов. Удаление азота осуществляется путем нитрификации и следующей за ней денитрификации. Нитрификация – процесс окисления ионов аммония NH_4^+ до нитратов NO_3^- , который осуществляется в два этапа. На первом этапе бактерии вида *Nitrosomonas* окисляют аммоний до нитрита NO_2^- по схеме



На втором этапе бактерии *Nitrobacter* окисляют нитрит до нитрата по схеме



Денитрификация – процесс восстановления нитратов до молекулярного азота.

В работе рассмотрена модель нитрификации, в которой процессы, связанные с окислением азота, рассматриваются отдельно от остальных процессов биоочистки:

$$\left\{ \begin{array}{l} \frac{dN_1}{dt} = -\mu_1 \frac{N_1}{K_{N_1} + N_1} B_1 \\ \frac{dN_2}{dt} = \frac{\mu_1}{Y_1} \frac{N_1}{K_{N_1} + N_1} B_1 - \frac{\mu_2}{Y_2} \frac{N_2}{K_{N_2} + N_2} B_2 \\ \frac{dN_3}{dt} = \frac{\mu_2}{Y_2} \frac{N_2}{K_{N_2} + N_2} B_2 \\ \frac{dB_1}{dt} = \mu_1 \frac{N_1}{K_{N_1} + N_1} - k_{d_1} B_1 \\ \frac{dB_2}{dt} = \mu_2 \frac{N_2}{K_{N_2} + N_2} - k_{d_2} B_2 \end{array} \right. \quad (3)$$

где N_1, N_2, N_3 – концентрации аммония, нитритов и нитратов соответственно; B_1, μ_1, k_{d_1} , и B_2, μ_2, k_{d_2} – концентрации, максимальные удельные скорости, константы отмирания микроорганизмов *Nitrosomonas* и *Nitrobacter* соответственно; Y_1, Y_2 – экономические коэффициенты; K_{N_1}, K_{N_2} – константы полунасыщения.

Модельная задача. Разделив первое уравнение на Y_1 и сложив первые три уравнения, получаем выражение N_3 через N_1, N_2 . Для поиска решения оставшейся системы четырех уравнений рассмотрим два подхода.

Первый подход состоит в построении решения PINN в виде [2]:

$$N_1(x) = \sum_{i=1}^N c_i v(x, \mathbf{a}_i), B_1(x) = \sum_{i=1}^N d_i v(x, \mathbf{b}_i), j = 1, 2$$

где в качестве базисных функций v выбраны $th(a(x - b))$.

Обучение проводится в процессе минимизации функции потерь:

$$E(N_1, B_1) = \sum_{i=1}^N \left[\left(\frac{dN_1}{dt} + \mu_1 \frac{N_1}{K_{N_1} + N_1} B_1 \right)^2 + \left(\frac{dB_1}{dt} - \mu_1 \frac{N_1}{K_{N_1} + N_1} + k_{d_1} B_1 \right)^2 (x_i) \right. \\ \left. + \delta (N_1(0) - N_{10})^2 + \delta (B_1(0) - B_{10})^2 \right] \quad (4)$$

Если имеются данные измерений, то в функцию потерь добавляется слагаемое, равное сумме квадратов отклонений выхода сети и измерений, умноженной на штрафной множитель.

Второй подход состоит в аналитической модификации классических численных методов (AMNM) и приводит к построению многослойных функциональных приближений [2, 3]. Суть модификации состоит в том, что классические методы применяются к промежутку переменной длины. В результате получается аналог нейронной сети глубокого обучения.

Результаты расчетов. Для концентрации аммония из упрощенной системы ОДУ были построены графики выходов нейросетей в сравнении с численным решением (рис. 1) после 2000 эпох обучения.




Рис. 1. Графики выхода нейросети в сравнении с численным решением пакета Математика для 10 нейронов и обучающей выборки размером $m = 300$

На рис. 1 кривая $N1_p(t)$ – выход нейросети для концентрации аммония, кривая $N1(t)$ – численное решение для концентрации аммония, кривая $B1_p(t)$ – выход нейросети для концентрации микроорганизмов *Nitrosomonas*, $B1(t)$ – численное решение для концентрации микроорганизмов. Для концентрации аммония и концентрации микроорганизмов *Nitrosomonas* было определено оптимальное количество нейронов при различных объемах данных в обучающей выборке.

На рис. 2 представлены графики с кривыми $Error\_N1\_best$ для лучших весов по функции потерь и графики с кривыми $Error\_B1\_best$.




Рис. 2. Графики MSE для обучающей выборки $m = 300$

Из рис. 2 видно, что при увеличении числа пробных точек эволюция MSE неоднородна для $Error\_N1$ и $Error\_B1$: в первом случае ошибки сначала уменьшаются, а затем наблюдается рост при одном локальном экстремуме (min); во втором случае наблюдается два локальных экстремума (max, min). При этом поведение MSE существенно отличается для различных значений выборок ($m = 100, 200, 300$).

Выводы. Представленные результаты позволяют сделать вывод, что решения с помощью PINN дают серию решений различного размера и точности. Построение многослойного решения, полученного на основе аналитической модификации численных методов, менее трудоемко, но для получения приемлемой точности требует периодической регенерации на основе измерений. Существенным достоинством таких моделей является явное включение в готовые формулы параметров задачи, что упрощает их идентификацию по измерениям. Проведенное исследование подтверждает наше убеждение [2, 9] в том, что многие практически интересные задачи могут быть решены без использования глубокого обучения и сложных нейросетевых конструкций.

Библиографический список

1. Kudryavtsev V. A., Rychkov S. L., Shatrov A. V. The Mathematical Modeling for Process of Biological Sewage Treatment // IOP Conference Series: Earth and Environmental Science, vol 321 (1). Code 152101. IOP Publishing, 2019.
2. Tarkhov D., Vasilyev A. Semi-Empirical Neural Network Modeling and Digital Twins Development. Cambridge, MA: Academic Press, 2020.
3. Lazovskaya T., Tarkhov D. Multilayer neural network models based on grid methods // IOP Conference Series: Materials Science and Engineering. Bristol, UK: IOP Publishing, 2016.
4. Boyarsky S., Lazovskaya T., Tarkhov D. Investigation of the predictive capabilities of a driven multilayer model by the Duffing oscillator // 2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon). Article 9271195.
5. Karniadakis G. et al. Physics-informed machine learning // Nature Reviews Physics. 2021. Vol. 3. P. 422–440.
6. Antonov V., Tarkhov D., Vasilyev A. Unified approach to constructing the neural network models of real objects. Part 1 // Mathematical Methods in the Applied Sciences. 2018. Vol. 41. P. 9244–9251.
7. Tarkhov D., Lazovskaya T., Malykhina G. Constructing Physics-Informed Neural Networks with Architecture Based on Analytical Modification of Numerical Methods by Solving the Problem of Modelling Processes in a Chemical Reactor // Sensors. 2023. Vol. 23, iss. 2. Article 663. DOI [10.3390/s23020663](https://doi.org/10.3390/s23020663)
8. Riedmiller M. Advanced supervised learning in multi-layer perceptrons – From backpropagation to adaptive learning algorithms // Computer Standards and Interfaces. 1994. Vol. 16, iss. 5. P. 265–278. DOI [10.1016/0920-5489\(94\)90017-5](https://doi.org/10.1016/0920-5489(94)90017-5)
9. Lazovskaya T. et al. Evolutionary PINN Learning Algorithms Inspired by Approximation to Pareto Front for Solving Ill-Posed Problems // Computation. 2023. Vol. 11, iss. 8. Article 166. DOI [10.3390/computation11080166](https://doi.org/10.3390/computation11080166)

TECHNOLOGY OF PHYSICALLY INFORMED NEURAL NETWORKS IN THE PROBLEM OF MATHEMATICAL MODELING FOR THE PROCESS OF BIOLOGICAL SEWAGE TREATMENT

Anatoly V. Shatrov
Vyacheslav D. Tarasov
Dmitry A. Tarkhov

St. Petersburg Polytechnic University of Peter the Great
29, Politekhnikeskaya Str., St. Petersburg, Russia, 195251
shatrov_av@spbstu.ru

The article presents a description and implementation of the technology of physically informed neural networks (PINN) on the example of a mathematical model of biological wastewater treatment. An algorithm for constructing a mathematical analysis of the process of nitrification of effluents in the system of urban treatment facilities based on PINN is proposed. PINN models and analytical modification of classical numerical methods are being compared. Optimal parameters of PINN models are searched.

Keywords: neural network technologies, mathematical modeling, biological wastewater treatment

ДОВЕРИЕ К СИСТЕМАМ ОБЪЯСНИМОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Попов Илларион Евгеньевич

Волгоградский государственный университет,
400062, Россия, г. Волгоград, пр. Университетский, 100
popov.larion@volsu.ru

Работа посвящена проблеме доверия к системам объяснимого искусственного интеллекта, в частности — к оценке степени уверенности в предлагаемых решениях. Рассматривается возможность сопоставления уровней уверенности различных моделей для формирования обоснований на основе более интерпретируемых алгоритмов. В рамках исследования анализируется явление сверхуверенности, проводится калибровка предсказаний и оценивается ожидаемая ошибка калибровки после корректировки вероятностных оценок.

Ключевые слова: объяснимый искусственный интеллект, нейронные сети, логистическая регрессия, калибровка моделей.

Введение. В системах искусственного интеллекта критически важным является доверие к ним экспертов, принимающих итоговые решения. Системы, вызывающие наибольшее доверие, обладают высокой точностью принятия решений и интерпретируемостью [2, 3]. Одним из методов построения таких систем является объединение высокоточных моделей, например, искусственных нейронных сетей и интерпретируемых моделей, например, случайного леса или ансамбля наивных байесовских классификаторов [1]. За счет того, что, как правило, любая модель машинного обучения оперирует вероятностными оценками, так называемой степенью уверенности, возможно сопоставление данных оценок разных моделей. Таким образом, для ансамбля классификаторов возможно получить модель, наиболее согласованную с решением нейронной сети.

Для сопоставления результатов необходимо доверие к вероятностным оценкам моделей [4, 5]. При этом следует отметить, что высокая точность сама по себе не гарантирует такого доверия. В ряде случаев возникает эффект сверхуверенности: модель практически всегда относит объект к определенному классу (если рассматривать задачу классификации) с близкой к 100% уверенностью, даже если решение оказывается ошибочным.

Постановка задачи и результаты. Обозначим за $C_{nn}(x)$ функцию принятия решения модели искусственной нейронной сети для объекта x . Пусть $C_1(x), \dots, C_m(x)$ — функции решений ансамбля интерпретируемых моделей. Каждая из этих функций представляет собой отображение вида

$$C: R^n \rightarrow [0; 1],$$

где n — размерность признакового пространства, а $[0; 1]$ интерпретируется как степень уверенности модели в принятом решении. Для построения интерпрета-

ции необходимо сопоставить модели нейронной сети одну из моделей ансамбля. Это можно осуществить путем поиска такой модели C_j , для которой достигается минимальное расстояние по степеням уверенности

$$j = \arg \min_{i=1 \dots m} (|C_{nn}(x) - C_i(x)|).$$

Однако такое сопоставление не всегда является корректным. Если высокоточная модель демонстрирует сверхуверенность, то предложенный метод будет выбирать из ансамбля модель, аналогично избыточно уверенную в своем решении, даже при ошибочном прогнозе. Это существенно снижает доверие к системам искусственного интеллекта, что особенно критично в таких сферах, как медицинская диагностика.

Для иллюстрации эффекта сверхуверенности были обучены две модели: логистическая регрессия и полносвязная нейронная сеть, решающие задачу определения группы риска рака молочной железы по степени выраженности температурных аномалий. На рис. 1 представлено распределение плотности уверенности моделей на тестовой выборке. Видно, что нейронная сеть демонстрирует более высокие значения уверенности; однако часть объектов с предсказаниями, близкими к 0 или 1, не принадлежит соответствующим классам. Таким образом, возникает задача калибровки уверенности $C(x)$ моделей.

Для повышения доверия к моделям используются различные стратегии сглаживания вероятностных оценок. Среди них можно выделить логит-преобразование, температурное сглаживание и квантильное преобразование. В данной работе применялся последний подход. Его суть заключается в разбиении плотности распределения уверенности на интервалы и последующем отображении этих интервалов на интервалы, соответствующие выбранному распределению. В рассматриваемом случае использовалось равномерное распределение.

На рис. 2 представлены результаты такого преобразования для полносвязной нейронной сети на подвыборке объектов, по которым модель допускала ошибки. Плотность распределения до преобразования показана оранжевым цветом, после преобразования — синим. Видно, что на этих объектах модель стала чаще «сомневаться», то есть ее уверенность смещается к значениям, близким к 0.5. Такое распределение не только повышает доверие к нейронной сети, но и облегчает выбор интерпретируемых моделей, которые также могут привести аргументы в пользу сложного диагностического случая.

Для количественной оценки эффекта калибровки рассчитывалась ожидаемая ошибка калибровки (Expected Calibration Error, ECE) по формуле

$$ECE = \sum_{k=1}^M \frac{|B_k|}{L} |acc(B_k) - conf(B_k)|,$$

где B_k — k -й интервал разбиения множества предсказаний, L — общее число объектов, $acc(B_k)$ — точность в интервале, $conf(B_k)$ — средняя уверенность модели в данном интервале.




Рис. 1. Сверхуверенность полносвязной нейронной сети




Рис. 2. Результаты калибровки уверенности модели полносвязной нейронной сети

Данная ошибка характеризует то, насколько уверенность модели совпадает с реальной точностью ее предсказания. Если значение ECE близко к 0, то предлагаемое моделью решение может быть понято интуитивно. То есть если модель предсказывает класс с уверенностью 0.8, то ожидается, что примерно 80% таких предсказаний верны. Если значение ECE высокое, то это свидетель-

ствует о сильном несоответствии между уверенностью и точностью. В результате калибровки значение ESE снизилось с 0.39 до 0.33.

Дополнительно была рассчитана средняя уверенность модели до и после калибровки на различных подвыборках объектов: корректно классифицированных здоровых, корректно классифицированных пациентов группы риска, а также ошибочно отнесенных к этим категориям. Результаты приведены в табл. 1. Как видно, после калибровки уверенность моделей существенно снизилась на ошибочных объектах, однако уменьшение наблюдается и для корректных предсказаний.

Таблица 1

Оценка степени уверенности модели

Оценка	Средняя уверенность по классу здоровых	Средняя уверенность по классу группы риска	Ошибочная средняя уверенность по классу здоровых	Ошибочная средняя уверенность по классу группы риска
До калибровки	0.82	0.79	0.945	0.92
После калибровки	0.66	0.62	0.78	0.77

Заключение. Таким образом, проведение калибровки уверенности сверхуверенной модели позволяет повысить доверие к системе искусственного интеллекта как за счет более интуитивного понимания уверенности, так и за счет возможности приведения интерпретации модели, соответствующей скорректированной уверенности.

Исследование выполнено за счет гранта Российского научного фонда № 25-21-00330, <https://rscf.ru/project/25-21-00330/>.

Библиографический список

1. Попов И.Е. Интерпретация математических моделей по данным микроволновой радиотермометрии / Математическая физика и компьютерное моделирование. 2025. Т. 28. №2. С. 62-80.
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. 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).
4. 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.
5. 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>.

TRUST IN EXPLAINABLE ARTIFICIAL INTELLIGENCE SYSTEMS

Illarion E. Popov

Volgograd State University,

400062, Russia, Volgograd, Universitetsky Ave., 100

popov.larion@volsu.ru

This paper examines the problem of trust in explainable artificial intelligence systems, specifically assessing the degree of confidence in proposed solutions. It explores the possibility of comparing confidence levels across different models to generate rationales based on more interpretable algorithms. The study analyzes the phenomenon of overconfidence, calibrates predictions, and estimates the expected calibration error after adjusting probabilistic estimates.

Keywords: explainable artificial intelligence, neural networks, logistic regression, model calibration.

УДК 519.2; 330.4; 004.8

СНИЖЕНИЕ ЭНТРОПИИ СОСТОЯНИЙ РЫНКА С ПОМОЩЬЮ ЭМПИРИЧЕСКОГО ПОКАЗАТЕЛЯ ХЁРСТА, УЧИТЫВАЮЩЕГО ЗНАК РЕГРЕССИИ

Иванов Александр Иванович

Пензенский научно-исследовательский электротехнический институт
440026, Россия, г. Пенза, ул. Советская, 9
ivan@pnici.penza.ru

Тарасов Дмитрий Викторович

Пензенский государственный университет
440026, Россия, г. Пенза, ул. Красная, 40
tarasovdv@mail.ru

В статье представлено описание процедуры, привязывающей показатель Хёрста к знаку регрессии и позволяющей снизить энтропию кодовых состояний модели. Предложенный подход должен способствовать выявлению персистентных и антиперсистентных состояний рынка, основываясь на данных малых выборок.

Ключевые слова: эмпирический показатель Хёрста, малые выборки, энтропия, регрессия, расстояние Хэмминга

Общие положения промышленного применения приложений нейросетевого искусственного интеллекта. Последние годы развитие искусственного интеллекта идет стремительными темпами, и для его повсеместного использования, конечно, требуются промышленные нейросетевые технологии. В соответствии с Указом Президента Российской Федерации от 10.10.2019 № 490¹ Россия должна стать к 2030 г. одним из мировых лидеров по созданию и применению эффективных приложений искусственного интеллекта. Одними из самых востребованных являются нейросетевые приложения искусственного интеллекта, конфиденциально обрабатывающие биометрические данные человека [1, с. 23]. В частности, под технологию конфиденциальной обработки биометрических данных в 2002 г. был создан международный технический комитет ISO/IEC JTC1 sc37 (Биометрия), усилиями которого было разработано около 170 международных стандартов. Эти стандарты ориентированы на размещение биометрических шаблонов в международных паспортах граждан России и других стран.

Предположительно существующая промышленная технология нейросетевого распознавания лиц может быть преобразована в нейросетевую технологию

автоматического распознавания «образов» трендов-«медведи» и «образов» трендов-«быки» при анализе состояний рынка [2].

Люди-трейдеры способны легко распознавать тренды роста цен («быки») и тренды падения цен («медведи») [3, 4], и, конечно, они способны к самообучению, чтобы все лучше и лучше угадывать текущие тренды на том или ином сегменте биржи.

Следует подчеркнуть, что далеко не все статистики чувствительны к текущему тренду состояния рынка. Например, важно отметить, что временные ряды имеют свойство сохранять последствия внешних воздействий на протяжении некоторого времени. Выражается подобное через автокорреляционную функцию: чем медленнее она убывает, тем дольше в ряду сохраняется влияние внешних факторов. Такое поведение принято описывать через термин «эффект памяти». Данная долгосрочная зависимость была обнаружена гидрологом Хёрстом [5], который прогнозировал ожидаемый уровень разливов реки Нил в Египте на эмпирических данных. В дальнейшем было показано, что эмпирический показатель Хёрста хорошо работает и при описании долговременной памяти многих фрактальных объектов [6]. Отметим, что поведение трендов на фондовом рынке также близко к фрактальным процессам.

Стоит сказать, что большие выборки данных о состоянии рынка препятствуют идее использования эмпирического показателя Хёрста для обучения нейросети. Поэтому необходимо пытаться оценивать значение эмпирического показателя Хёрста на малых выборках (не более календарного месяца или чуть более 20 рабочих дней). Эта задача является вполне реальной, если скорректировать методическую ошибку, возникающую из-за малого объема выборок [7]:

$$Xr(21) = \frac{\log_{10} \{Rs(x) / \sigma(x)\}}{\log_{10} \{21\pi / 2\}} - 0,077, \quad (1)$$

где $Rs(x)$ – размах данных в малой выборке объемом в 21 опыт; $\sigma(x)$ – стандартное отклонение малой выборки; 0,077 – аддитивный компенсатор методической погрешности для малой выборки объемом в 21 опыт, обеспечивающий выполнение условия $Xr(21) \approx 0,5$ на входном белом шуме.

Полученный скорректированный показатель Хёрста (1) по-прежнему нечувствителен к трендам рынка, другими словами, показатель не способен различать персистентное и антиперсистентное состояния рынка. Чувствительность к тренду малой выборки может быть добавлена определением модифицированного эмпирического показателя Хёрста [8]:

$$sXr(21) = \text{sign} \{i_{\max} - j_{\min}\} \cdot \left\{ \frac{\log_{10} \{Rs(x) / \sigma(x)\}}{\log_{10} \{21\pi / 2\}} - 0,077 \right\}, \quad (2)$$

где $i_{\max}$ – номер точки, соответствующей максимуму в малой выборке; $j_{\min}$ – номер точки, соответствующей минимуму в малой выборке.

Снижение энтропии состояний рынка. Разметка данных рынка на тренды противоположных знаков является достаточно сложной задачей, которую опытные трейдеры решают на уровне опыта и интуиции. Видимо, со временем эта задача будет формализована и появятся достаточно надежные автоматы, распознающие знак текущего тренда [2]. Как строить подобные автоматы разной сложности (разного уровня интеллектуальности), пока не понятно. Тем не менее мы можем построить простейший устойчивый автомат, который работает по следующему решающему правилу:

$$\begin{cases} \text{sign}(dx_i / dt) \leftarrow 1 & \text{если } x_i < x_{i+1}, \\ \text{sign}(dx_i / dt) \leftarrow 0 & \text{если } x_i \geq x_{i+1}. \end{cases} \quad (3)$$

Возможно, будущий эффективный автомат разметки данных должен будет игнорировать некоторые скачки их состояний с малой амплитудой, а пока будем решать эту задачу, опираясь на интервал данных, расположенных между максимумом и минимумом анализируемой малой выборки.

Пример работы подобного автомата разметки данных котировок акций ЛУКОЙЛ, взятых с финансового портала MDF.ru¹, представлен на рис. 1, 2.

На рис. 1 представлена ситуация, когда максимум появляется раньше минимума. Следовательно, текущий тренд состояния рынка соответствует снижению цен «медведи». При этом высокая уверенность в том, что обнаружен тренд «медведи», применима только к интервалу между экстремумами анализируемой малой выборки.




Рис. 1. Разметка котировок акций ЛУКОЙЛ на фрагменты «быки/медведи» в случае, когда максимум следует ранее минимума в малой выборке (данные за период с 19.05.2025 по 17.06.2025)

¹ URL: <https://clck.ru/3PZTiL> (дата обращения: 17.09.2025).

Скорректируем двоичную последовательность смены знаков тренда, присвоив состояние «0» всем колебаниям цен внутри интервала между экстремумами. В случае изменения тренда между экстремумами на «быки» данный интервал между ними следует заполнять единицами (рис. 2).




Рис. 2. Разметка котировок акций ЛУКОЙЛ на фрагменты «быки/медведи» в случае, когда минимум следует ранее максимума в малой выборке (данные за период с 25.07.2025 по 22.08.2025)

В целом предложенный алгоритм разметки данных примитивен, однако он верно отражает ситуацию на рынке:

- если рынок персистентен на длинных интервалах анализа, то «быки» должны преобладать над «медведями» либо по времени, либо по амплитуде;
- если долговременный тренд антиперсистентен, то ситуация должна быть обратной.

Расстояние Хэмминга как оценка энтропии рынка. Поведение временных рядов, определяющих курс на рынке, можно рассматривать как совокупность нескольких компонент: долгосрочная тенденция или тренд; сезонные колебания, т.е. повторяются модели поведения; нерегулярные экономические циклы, иначе – блуждающие; случайный, нерегулярный шум. А искусственный интеллект при анализе временных рядов можно рассматривать как инструмент борьбы с присутствующими в них хаотическими составляющими, оцениваемыми через энтропию. Поэтому мы можем оценивать эффективность той или иной процедуры, например предсказания знака регрессии, оценивая энтропию данных до и после ее применения.

Конечно, классическая формула оценки энтропии по Шеннону относится к операциям с экспоненциальной вычислительной сложностью и ее прямое использование неприменимо на практике. Одним из путей снижения вычислительной сложности алгоритмов оценки энтропии является переход от анализа статистик

бинарных кодов к анализу статистик распределения расстояний Хэмминга [9], в нашем случае согласно формуле

$$h = \sum_{i=0}^{19} "bm_i" \oplus 0,$$

где $"bm_i"$ – i -й разряд скорректированной бинарной последовательности «быки / медведи».

Представленное на рис. 3 распределение расстояний Хэмминга оценок энтропии для идеального белого шума в случае наличия тренда будет смещаться. При этом могут возникнуть такие группы распределений расстояний Хэмминга:

- участки подъема цен («быки») приведут к смещению вправо спектральных линий расстояний Хэмминга. Причем разряды кодировок фрагментов колебания цен почти всегда имеют состояний «1» больше, чем состояний «0»;
- участки подъема цен («медведи») приведут к смещению влево спектральных линий расстояний Хэмминга. А разряды кодировок таких цепочек содержат состояний «0» почти всегда больше, чем состояний «1».




Рис. 3. Симметричное распределение расстояний Хэмминга для идеального белого шума

Заключение. На примере малых выборок рассмотрены возможные модификации расчета эмпирического показателя Хёрста, направленные на выявление скрытых закономерностей поведения финансовых временных рядов и снижение энтропии.

Библиографический список

1. Болл Р. М., Коннел Дж. Х., Панканти Ш., Ратха Н. К., Сеньор Э. У. Руководство по биометрии. М.: Техносфера, 2007. 368 с.
2. Иванов А. И. Экономика промышленного интеллекта: получение сверхприбыли и сокращение рабочих мест // Системы безопасности. 2024. № 1. С. 140–142.
3. Найман Э. Как покупать дешево и продавать дорого. Пособие для разумного инвестора. М.: Альпина Паблишер, 2011. 552 с.
4. Орлов Ю. Н., Осминин К. П. Нестационарные временные ряды. Методы прогнозирования с применением анализа финансовых и сырьевых рынков. М.: Ленанд, 2023. 384 с.
5. Hurst H. E. Long-term Storage of Reservoirs // Transactions of American Society of Civil Engineers. 1951. Vol. 116, iss. 1. DOI 10.1061/TACEAT.0006518
6. Шредер М. Фракталы, хаос, степенные законы. Миниатюры из бесконечного рая. Ижевск: НИЦ «Регулярная и хаотическая динамика», 2005. 528 с.

7. Волчихин В. И., Иванов А. И., Тихомиров В. А., Тарасов Д. В. Быстрый алгоритм робастных оценок показателя Хёрста при анализе малых выборок биометрических данных и данных рынка // Известия высших учебных заведений. Поволжский регион. Технические науки. 2024. № 1. С. 48–55. DOI 10.21685/2072-3059-2024-1-4

8. Тарасов Д. В., Иванов А. И., Ермакова А. И. Устранение неопределенности показателя Хёрста по отношению к знаку регрессии экономических или биометрических данных на малых выборках // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2025. № 2. С. 116–124. DOI [10.24143/2072-9502-2025-2-116-124](https://doi.org/10.24143/2072-9502-2025-2-116-124). EDN BRQCTE

9. Малыгин А. Ю., Волчихин В. И., Иванов А. И., Фунтиков В. А. Быстрые алгоритмы тестирования нейросетевых механизмов биометрико-криптографической защиты информации. Пенза: Изд-во ПГУ, 2006. 161 с.

REDUCING THE ENTROPY OF MARKET CONDITIONS USING THE EMPIRICAL HURST INDICATOR, WHICH TAKES INTO ACCOUNT THE REGRESSION SIGN

Alexander I. Ivanov

Penza Scientific Research Electrotechnical Institute
9, Sovetskaya Str., Penza, Russia, 440026
ivan@pniei.penza.ru

Dmitry V. Tarasov

Penza State University
40, Krasnaya Str., Penza, Russia, 440026
tarasovdv@mail.ru

The article describes a procedure that binds the Hurst exponent to the regression sign and reduces the entropy of the model's code states. The proposed approach should help identify persistent and anti-persistent market conditions based on small sample data.

Keywords: empirical Hurst index, small samples, entropy, regression, Hamming distance

ОСНОВНЫЕ ФУНКЦИИ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ АДАПТИВНОЙ МНОГОКРИТЕРИАЛЬНОЙ ОПТИМИЗАЦИИ ИНВЕСТИЦИОННОГО ПРОЕКТИРОВАНИЯ

Шорилов Андрей Федорович

Институт экономики УрО РАН
Россия, 620014, г. Екатеринбург, ул. Московская, 29
afshorikov@mail.ru

Буценко Елена Владимировна

Уральский государственный экономический университет
Россия, 620144, г. Екатеринбург, ул. 8 Марта, 62
evl@usue.ru

В статье приведено описание структуры и основных функций интеллектуальной компьютерной программной системы адаптивной многокритериальной оптимизации процессов инвестиционного проектирования. Данная программная система разработана на основе новых моделей и методов сетевого экономико-математического моделирования оптимизации управления процессами инвестиционного проектирования. На основе решения набора задач сетевого моделирования процессов инвестиционного проектирования, соответствующих допустимым технологиям и различным вариантам их осуществления с использованием алгоритма построения критических путей и метода скаляризации выбранной векторной целевой функции разработана методика решения сформированной задачи векторной оптимизации. Данная методика положена в основу создания интеллектуальной компьютерной программной системы адаптивной многокритериальной оптимизации процессов инвестиционного проектирования. Созданная интеллектуальная компьютерная программная система позволяет реализовать автоматизацию и адаптивную оптимизацию управления реализацией сложных инвестиционных проектов.

Ключевые слова: инвестиционное проектирование, оптимизация управления инвестициями, сетевое экономико-математическое моделирование, оптимальное адаптивное управление, векторная оптимизация, календарное планирование, интеллектуальная компьютерная система

Введение. Для решения проблемы эффективного управления инвестиционными проектами требуется разработка и создание компьютерного программного инструментария, позволяющего автоматизировать и реализовать оптимизацию процессов проектирования и принятия решений в этой сфере. При этом одной из ключевых задач в этой области является необходимость учета множества факторов, таких как наличие нескольких допустимых технологий, позволяющих реализовать рассматриваемый инвестиционный проект и различные варианты их осуществления, ограниченность ресурсов, временные рамки и многокритериальность целевой функции. Существующие подходы к управлению инвестиционным проектированием в своем большинстве не учитывают всей сложности и многогранности таких процессов, что приводит к неоптимальным решениям и увеличению рисков при их реализации. Поэтому разработка интеллектуальных компь-

ютерных программных систем, способных автоматизировать и оптимизировать адаптивное управление инвестиционным проектированием на основе современных экономико-математических моделей и методов, является актуальной задачей.

В данной статье рассматривается структура и основные функции разработанной и созданной интеллектуальной компьютерной программной системы адаптивной многокритериальной оптимизации процессов инвестиционного проектирования. В качестве основного инструментария при создании данной программной системы используются сетевые модели и методы, которые позволяют учитывать сложные взаимосвязи между работами-операциями при моделировании реализации инвестиционного проекта, а также многокритериальность целевых функций. Предлагаемая в работе новая оптимизационная сетевая экономико-математическая модель учитывает наличие нескольких допустимых технологий при реализации инвестиционного проектирования, различных вариантов их осуществления, использует соответствующую рассматриваемым процессам векторную целевую функцию для оценки качества реализации инвестиционного проектирования и позволяет реализовать адаптивную оптимизацию относительно изменения состояния системы и возникающих новых условий и ограничений.

Данная статья примыкает к исследованиям [1–9] и основывается на результатах, представленных в работах [10–12].

Постановка задачи и результаты исследования. Под *оптимизацией управления процессами инвестиционного проектирования* будем понимать выбор оптимальной технологии его реализации и оптимального варианта ее реализации (или нескольких вариантов), которые соответствуют максимальному (минимальному) значению сформированной специальной векторной целевой функции, оценивающей общую стоимость, длительность и качество реализации рассматриваемого проекта в целом. *Адаптивная многокритериальная оптимизация* позволяет учитывать возможность использования измерений состояния системы, возникновение новых условий и ограничений, а также реализовать обратную связь при осуществлении инвестиционного проектирования.

Для решения рассматриваемой конкретной задачи инвестиционного проектирования для каждой допустимой технологии реализации проекта и конкретных вариантов ее осуществления предлагается сформировать соответствующую сетевую модель (или несколько моделей), включающую всю последовательность работ-операций, необходимых для реализации инвестиционного проекта, отображающую их упорядоченность по времени и последовательности выполнения. Затем применяется метод многокритериальной оптимизации сетевого моделирования управления проектами при наличии нескольких допустимых технологий их реализации [10]. Далее реализуется адаптивная многокритериальная оптимизация инвестиционного проектирования с помощью методов адаптивного управления (рис. 1) [11, 12].

Методика адаптивной многокритериальной оптимизации процессов инвестиционного проектирования, учитывающая наличие нескольких допустимых технологий реализации конкретного проекта, различные варианты их осуществления и векторной целевой функции, описывается в виде 18 шагов алгоритма, записанных в форме псевдокода. Основой предлагаемой методики является се-

тевая математическая модель адаптивной многокритериальной оптимизации управления проектами при наличии нескольких допустимых технологий их реализации, представленная А. Ф. Шориковым в работах [10, 11].



Рис. 1. Схема адаптивной оптимизации управления инвестиционным проектированием

Особенности реализации алгоритма:

- веса для скаляризации векторного функционала, такие как ВесаДлительности, ВесаСтоимости, ВесаКачества, можно определить либо экспертной оценкой, либо в результате численного эксперимента или решения соответствующей оптимизационной задачи;
- для выбора наилучших действий реализуется *стратегия оптимального адаптивного управления* [10, 12], состоящая из двух частей: алгоритма UE (Стратегия1 – формирование сетевой модели, отвечающей оптимальной позиции процесса РЕ-позиции, состоящей из оставшихся работ-операций); алгоритма U (Стратегия2 – формирование сетевой модели, отвечающей неоптимальной позиции процесса – Р-позиции, включающей не выполненные из-за задержек работы-операции и оставшиеся для выполнения работы-операции);
- определение условия пересчета сети («нужно пересчитать сеть»), которое запускает процесс повторного формирования сетевой модели и критического пути, основано на величине задержек исполнения работ-операций и невыполненных работах-операциях;
- псевдокод реализует общий алгоритм адаптивной многокритериальной оптимизации инвестиционного проектирования при наличии нескольких допустимых технологий реализации проекта, различные варианты их осуществления и векторной целевой функции, учитывая специфические особенности конкретного рассматриваемого проекта.

Программный инструментарий. Для реализации предложенной методики разработана *интеллектуальная компьютерная программная система адаптивной многокритериальной оптимизации инвестиционного проектирования* Оптимум-Инвест (рис. 2). Решатель задач содержит основные процедуры, реализующие формирование сетевой модели, критического пути и критического времени для реализации проекта, формирование позиции управления, формирование оптимальной адаптивной стратегии управления инвестиционным проектированием, а также формирование и отображение результатов решения рассматриваемой задачи.




Рис. 2. Реализация адаптивной многокритериальной оптимизации инвестиционного проектирования

Каждый класс, или модуль, программного комплекса ОптимумИнвест содержит несколько подклассов. Для всех классов разработаны необходимые методы объектно-ориентированного программирования, используемые в процессе формирования сетевой модели проекта и ее оптимизации. Диаграмма классов программного комплекса представлена созданными классами (рис. 3).





Рис. 3. Структура интеллектуального компьютерного программного комплекса ОптимумИнвест

В начале работы в программном комплексе ОптимумИнвест пользователю предлагается выбрать задачу оптимизации инвестиционного проектирования и ввести исходные данные о проекте (рис. 4). Далее для каждой допустимой технологии реализации проекта и каждого варианта ее реализации строится сетевая модель проекта, производится расчет показателей сетевого моделирования, поиск критических работ-операций проекта, формирование критических путей и критического времени проекта, которые запоминаются. В результате решения задачи многокритериальной оптимизации вычисляются оптимальная технология и соответствующий оптимальный вариант ее реализации. Затем для оптимального варианта реализации оптимальной технологии осуществления рассматриваемого проекта и соответствующей сетевой модели формируется диаграмма Ганта с отображением обычных и критических работ-операций, свободного резерва работ-операций и реализованных критических работ-операций (рис. 5). Осуществление стратегии адаптивной многокритериальной оптимизации в каж-

дый допустимый период выполняется в соответствии со следующей схемой: при реализации оптимальной РЕ-позиции системы выполняются плановые работы-операции; при возникновении сбоя (например, задержек работ-операций), т.е. реализации неоптимальной Р-позиции системы, осуществляется оценка реальной ситуации и программа перестраивает сетевую модель, рассчитывает новый критический путь и строит новый календарный график с учетом новой фактической информации об исполнении оставшихся работ-операций проекта (рис. 6).



№	Описание	Продолжительность	Предшественники операции
R1	Изучение рынка и определение концепции проекта	2	
R2	Регистрация и оформление документов	4	
R3	Ремонт и дизайн помещения	4	1
R4	Фасадные работы	2	3
R5	Покупка оборудования для цеха и гостевого зала	2	1
R6	Установка и монтаж оборудования	2	5
R7	Формирование ассортимента выпускаемой продукции	1	1
R8	План продаж и маркетинг	1	7
R9	Реклама	1	8
R10	План производства кондитерского цеха	1	5
R11	Организационный план (штатное расписание и фонд оплаты труда)	1	10
R12	Договор с поставщиками	2	10
R13	Финансовый план	1	11
R14	Оценка эффективности	1	13
R15	Оценка рисков	1	13

Рис. 4. Исходная информация для реализации адаптивной многокритериальной оптимизации инвестиционным проектированием




Рис. 5. Календарный график с отображением работ-операций конкретного инвестиционного проекта




Рис. 6. Формирование нового календарного графика с учетом получения фактической информации о реализации инвестиционного проекта

Заключение. В работе представлена новая методика адаптивной многокритериальной оптимизации инвестиционного проектирования, основанная на использовании сетевого экономико-математического моделирования и векторной целевой функции. Разработанная сетевая модель учитывает наличие нескольких допустимых технологий реализации конкретного инвестиционного проекта, различные варианты их осуществления и использует векторную целевую функцию для оценки качества их выполнения. Это позволяет более гибко и эффективно учитывать многокритериальность исходной задачи и ситуаций, возникающих в процессе управления сложными инвестиционными проектами [10–12].

Предложенная методика включает использование метода скаляризации для нахождения оптимального решения формализованной задачи векторной оптимизации; решение задачи сетевого моделирования, соответствующей сформированной оптимальной технологии и оптимального варианта ее реализации; формирование критического пути и вычисление критического (оптимального) времени реализации проекта; формирование календарного графика исполнения работ-операций; реализацию стратегии оптимального адаптивного управления процессами инвестиционного проектирования в зависимости от реального состояния системы. Реализация данных процедур обеспечивает возможность автоматизации и оптимизации процессов планирования, управления ресурсами и сроками выполнения инвестиционных проектов.

На основе разработанной методики создана интеллектуальная компьютерная программная система ОптимумИнвест, которая позволяет автоматизировать процесс принятия управленческих решений, оптимизировать выполнение операций и минимизировать риски, связанные с реализацией инвестиционных проектов, путем введения обратной связи. Практическое применение данной системы способствует повышению эффективности управления инвестиционным проектированием, сокращению временных и финансовых затрат, а также улучшению качества принимаемых решений.

Финансирование. Статья подготовлена в соответствии с государственным заданием для ФГБУН Институт экономики УрО РАН и ФГБОУ ВО Уральский государственный экономический университет на 2023–2025 гг.

Библиографический список

1. Kelley J. E., Walker M. R. Critical-Path Planning and Scheduling // Proceedings of the Eastern Joint Computer Conference. 1959. P. 160–173. DOI 10.1145/1460299.1460318
2. Malcolm D. G., Roseboom J. H., Clark C. E., Fazar W. Application of a Technique for Research and Development Program Evaluation // Operations Research. 1959. Vol. 7, no. 5. P. 646–669. DOI 10.1287/opre.7.5.646
3. Hwang C. L., Masud A. S. M. Multiple Objective Decision Making – Methods and Applications: A State-of-the-Art Survey. Springer-Verlag, 1979. DOI: 10.1007/978-3-642-45511-7
4. Zeleny M. Multiple Criteria Decision Making. McGraw-Hill, 1982.
5. Kerzner H. Project Management: A Systems Approach to Planning, Scheduling, and Controlling. John Wiley & Sons, 2017.
6. A Guide to the Project Management Body of Knowledge (PMBOK Guide). 7th Edition. Project Management Institute, 2021.
7. Turban E., Sharda R., Delen D. Decision Support and Business Intelligence Systems. Pearson Education, 2010.
8. Power D. J., Sharda R. Model-Driven Decision Support Systems: Concepts and Research Directions // Decision Support Systems. 2007. Vol. 43, no. 3. P. 1044–1061. DOI 10.1016/j.dss.2005.05.030

9. Ширяев В. И. Алгоритмы управления динамическими системами в условиях неопределенности. Часть 1 // Мехатроника, автоматизация, управление. 2024. Т. 25, № 6. С. 279–288. DOI 10.17587/mau.25.279-288

10. Шориков А. Ф. Сетевая модель для многокритериальной оптимизации управления проектами // Системное моделирование социально-экономических процессов: труды 39-й междунар. науч. школы-семинара им. акад. С. С. Шаталина, г. Санкт-Петербург, 30 сентября – 6 октября 2016 г. / под ред. д-ра экон. наук В. Г. Гребенникова, д-ра экон. наук И. Н. Щепиной. Воронеж: Воронежский государственный педагогический университет, 2016. С. 370–374.

11. Шориков А. Ф. Сетевая математическая модель оптимизации адаптивного управления проектами при наличии нескольких технологий их реализации // Анализ, моделирование, управление, развитие социально-экономических систем (АМУР-2020): XIV Всерос. с междунар. участием школа-симпозиум: сб. науч. тр. Симферополь: ИП Корниенко А.А., 2020. С. 399–405.

12. Шориков А. Ф., Буценко Е. В. Сетевое моделирование оптимизации процессов инвестиционного проектирования при наличии нескольких технологий // Вестник УрФУ. Серия: Экономика и управление. 2016. Т. 15, № 6. С. 926–943. DOI 10.15826/vestnik.2016.15.6.046

MAIN FUNCTIONS OF THE INTELLIGENT SYSTEM OF ADAPTIVE MULTICRITERIAL OPTIMIZATION OF INVESTMENT DESIGN

Andrey F. Shorikov

Institute of Economic of the Ural Branch of the Russian Academy of Sciences
29, Moskovskaya Str., Ekaterinburg, Russia, 620014
afshorikov@mail.ru

Elena V. Butsenko

Ural State University of Economics
62, 8 Marta Str., Ekaterinburg, Russia, 620144
evl@usue.ru

The article describes the structure and main functions of the intelligent computer software system for adaptive multi-criteria optimization of investment design processes. This software system was developed on the basis of new models and methods of network economic and mathematical modeling for optimizing the management of investment design processes. Based on the solution of a set of network modeling problems of investment design processes corresponding to acceptable technologies and various options for their implementation, using the algorithm for constructing critical paths and the scalarization method of the selected vector objective function, a methodology for solving the formed vector optimization problem has been developed. This technique is the basis for creating an intelligent computer software system for adaptive multi-criteria optimization of investment design processes. The created intelligent computer software system allows for automation and adaptive optimization of management of complex investment projects.

Keywords: investment design, investment management optimization, network economic and mathematical modeling, optimal adaptive control, vector optimization, calendar planning, intelligent computer system

ВЕРОЯТНОСТНО-ФРАКТАЛЬНЫЙ ПОДХОД К РАНЖИРОВАНИЮ НАЛОГОПЛАТЕЛЬЩИКОВ НА ОСНОВЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ НАЛОГОВОГО КОНТРОЛЯ

Бирюков Александр Николаевич

Стерлитамакский филиал Уфимского университета науки и технологий
453103, Россия, Республика Башкортостан, г. Стерлитамак, проспект Ленина, 49
biryukov_str@mail.ru

Глущенко Ольга Ивановна

Стерлитамакский политехнический колледж
453104, Россия, Республика Башкортостан, г. Стерлитамак, ул. Социалистическая, д. 5
olga.glushhenko@mail.ru

В статье представлен вероятностно-фрактальный подход к ранжированию налогоплательщиков на основе нейросетевой модели с целью повышения эффективности налогового контроля. Практическая значимость подхода заключается в создании оптимальных планов налогового контроля, которые повышают точность выявления нарушений и снижают нагрузку на контролирующие органы. Предложенный метод открывает перспективы для развития нейросетевого налогового мониторинга и анализа больших данных с учетом сложной структуры и природы налоговой отчетности.

Ключевые слова: нейросетевая модель, налоговая декларация, вероятностный подход, фрактальный подход, ранжирование налогоплательщиков, налоговый контроль

Введение. В современных условиях развития налогового контроля возникает необходимость в совершенствовании методов анализа налоговых деклараций с целью повышения точности выявления нарушений и оптимизации использования ресурсов контролирующих органов. Традиционные подходы, основанные на изолированном рассмотрении данных отдельного налогоплательщика, часто не позволяют эффективно выявлять систематические искажения и риски, связанные с налоговой отчетностью. В данной работе предлагается новая концепция, основанная на сравнительном анализе показателей налогоплательщиков в рамках нейросетевой модели, учитывающей вероятностные и фрактальные свойства данных. Такой подход позволяет не только выявлять аномальные отклонения, но и учитывать их сложную природу, обусловленную как случайными, так и систематическими факторами, что делает процедуру ранжирования налогоплательщиков более адекватной и устойчивой к помехам. Введение вероятностных и фрактальных критериев ранжирования способствует формированию более точных и информативных алгоритмов отбора объектов для выездных проверок, что важно для повышения эффективности камерального налогового контроля.

1. Двойственная природа больших отклонений как результат неполного подавления дисфункций структурируемой математико-информационной системы. Раскроем суть идей, заложенных в эту концепцию, и их связь с общесистемными законами. Главная идея состоит в том, что, в отличие от су-

существующих технологий налогового контроля, камеральный анализ декларации отдельного налогоплательщика целесообразно проводить не изолированно, а в сравнении с показателями других налогоплательщиков, отраженных в эталонном фоне, т.е. в нейросетевой модели $\hat{Y}(\vec{X}, W)$ вида

$$\hat{Y} = F(\vec{X}, W); \vec{X} \in R^n \xrightarrow{F} \hat{Y} \in R^m. \quad (1)$$

При этом в соответствии с общесистемной фоновой закономерностью полезным сигналом, отраженным от фона, является относительное отклонение

$$\delta_i = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\%. \quad (2)$$

На основе этого отклонения от фона и строятся алгоритмы отбора налогоплательщиков с помощью вероятностных и фрактальных подходов.

При интерпретации отклонений экспериментальных значений моделируемого показателя y_i от эталонных $\hat{y}_i$ в (2) могут возникать ошибки I и II рода («пропуск цели» или «ложная тревога»), т.е. неопределенность, которая вытекает как следствие из общесистемного закона о неполном подавлении дисфункций при структурировании математико-информационной системы.

Поясним это на конкретном примере задачи налогового контроля на стадии камеральных проверок. Пусть построена нейросетевая модель (НСМ) и вычислено множество относительных отклонений $\{\delta_i\}, i = \overline{1, N}$. Как интерпретировать большие отклонения порядка сотен процентов? Природа таких отклонений двойственна.

В НСМ аппроксимации «производственной функции» объекта налогового контроля полезное взаимодействие (многоуровневое иерархическое структурирование, «эксплуатация» свойств нелинейной взаимосвязи компонент вектора входных факторов и обучения НСМ в условиях сильной зашумленности) порождает неоднозначную (вероятностную) оценку моделируемого показателя. Это практически приводит к неопределенности в интерпретации больших отклонений между расчетными («эталонными») и декларированными значениями моделируемого показателя Y вида (2).

Действительно, в силу вероятностного характера оценки случайной величины Y в нейросети (НС) даже хорошо обученная, адекватная и имеющая высокую точность НСМ «имеет право» на существование небольшого числа точек тестового множества, где имеются большие отклонения (2). Число этих точек задается пользователем при обучении НСМ и его нельзя сделать равным 0, ибо время обучения может стать недопустимым. Тогда становится неясным, чем вызваны большие отклонения в данных точках: ошибками расчета нейросети или это случай сознательного искажения деклараций на фоне условного математического ожидания (1)? Должен быть предусмотрен некоторый защитный (иммунный) механизм подавления указанных выше дисфункций математико-информационной модели. В качестве такого механизма может быть предложен *вероятностный* либо *фрактальный* критерий ранжирования.

Действительно, использование отклонения $\delta(2)$ как меры недоверности отчетной документации имеет следующие недостатки [2]:

1) специфика предметной области такова, что наиболее информативны в аспекте увеличения налоговых доначислений субъекты, у которых отклонения являются результатов сознательного систематического искажения информации. Отсюда следует, что необходимо учитывать предысторию каждого g -го объекта налогового контроля;

2) возникают случайные искажения показателей налоговой декларации;

3) имеется некоторая вероятность появления больших случайных ошибок обобщения, обусловленная самим алгоритмом нейросети (НС) (квадратичный критерий аппроксимации) так как квадратичный критерий обучения сети гарантирует малость ошибок только в среднем.

Устранить третий недостаток использования δ как меры дискриминации налогоплательщиков по степени искажения ими налоговых деклараций позволяет метод оценки адекватности НСМ на основе байесовского подхода. В отношении второй и третьей причин отметим, что возможны следующие случаи появления больших отклонений δ :

а) большое отклонение δ вызвано кратковременными случайными дестабилизирующими факторами в момент прогнозных оценок t_0 ;

б) большое отклонение δ обусловлено систематическим сознательным искажением отчетной документации.

Для снижения чувствительности δ к помехам, т.е. для подавления дисфункций, предлагается ввести меру риска, получаемую методами математической статистики, учитывающую предысторию конкретного объекта налогового контроля по следующему алгоритму.

2. Вероятностный подход к оценке неопределенности в задаче ранжирования налогоплательщиков. Идея вероятностного подхода (мера уменьшения неопределенности) при разработке критерия отбора налогоплательщиков для выездных проверок состоит в том, что этот критерий должен аккумулировать в себе как оценку величины отклонения (2), так и вероятность этого отклонения. Предлагается в качестве такого критерия мультипликативная свертка:

$$\psi_g = \tilde{\delta}_{gt} \Big|_{t=t_0} \cdot P(\delta_g \geq \tilde{\delta}) \Big|_{t_0} \cdot M_g. \quad (3)$$

где $\tilde{\delta}_{gt} = \delta_{gt} + U$ – значение верхней границы доверительного интервала для отклонения δ_{gt} ($\delta_{gt} = \delta_i$), т.е. в записи отклонения фиксируется номер налогоплательщика g и момент наблюдения t); $P(\delta_g \geq \tilde{\delta}) \Big|_{t_0}$ – вероятность события, что ожидаемое значение отклонения δ_g моделируемой случайной величины Y будет больше выборочного среднего $\bar{\delta}$ с учетом его смещения на полуширину доверительного интервала для $\{\delta_g\}$; t_0 – момент времени, соответствующий последним данным декларации при ранжировании налогоплательщиков; M_g – экспертно задаваемый коэффициент масштаба g -го налогоплательщика.

Таким образом, задача ранжирования налогоплательщиков по критерию Ψ требует решения как минимум трех взаимосвязанных задач:

- 1) задачи аппроксимации базы данных с помощью стохастических математической модели (1) и вычисления по ней отклонений (2);
- 2) вычисления доверительных интервалов для отклонений U ;
- 3) задачи ранжирования по вероятностному критерию (3).

3. Фрактальный подход к оценке неопределенности в задаче ранжирования налогоплательщиков. Вероятностный подход в задаче ранжирования налогоплательщиков, изложенный в пункте 2, имеет существенное ограничение, влияющее на оценку риска ошибок I и II рода при отборе налогоплательщиков: постулируется нормальный закон распределения плотности вероятности, $f(\delta)$, от носительных случайных остатков $\{\delta_i\}$ моделируемой случайной величины Y (выручки) по (2) (без взятия операции модуля для δ_i).

В пробных вычислительных экспериментах было установлено, что закон распределения остатков $\{\delta_i\}$ для реальных данных зачастую существенно отличается от нормального в силу наличия «тяжелых хвостов» функции $f(\delta)$. Поэтому при оценке риска ошибок I и II рода приходится вместо аналитических операций на основе функции Лапласа вводить вычислительные процедуры построения гистограмм. Точность расчетов по гистограммам при дефиците наблюдений снижается.

Соответственно разработан другой подход к построению отбора Ψ , основанный на теории фракталов (феномен хаоса). В качестве числовой меры оценки предыстории появления больших отклонений $\{\delta_i\}$ предлагается принципиально новая числовая мера риска – фрактальная размерность временного ряда относительных остатков $\{\delta_i\}$, которая измеряет степень валидности кривой этого ряда. Как известно, фрактальная размерность является весьма устойчивой статистической характеристикой степени колеблемости («изрезанности») временного ряда и, следовательно, может служить подходящей мерой риска для случаев отсутствия нормального (или логнормального) распределения. Чем меньше фрактальная размерность D_g кривой, $\{\delta_g(t)\}$, тем более устойчиво появление больших отклонений (2), тем меньше риск ошибок идентификации g -го налогоплательщика как нарушителя налоговой дисциплины. При этом критерий отбора получит вид

$$\Psi_g = (\delta_g|_{t=t_0}) \cdot D^{-1} \cdot M_g; g = \overline{1, G}. \quad (4)$$

Здесь большим суммам ожидаемого доначисления налоговых выплат при документальных проверках соответствуют большие значения критерия Ψ_g .

Для применения фрактального подхода, естественно, требуются данные панельного типа, в которых наблюдения упорядочены как по объектам (налогоплательщикам), так и по времени $t = \overline{1, T}$ [1].

В пользу предлагаемого подхода к отбору налогоплательщиков для выездных проверок (4) говорят следующие соображения [3]. Временной ряд $\{\delta_g(t)\}$ доходностей ценных бумаг далек от «случайного блуждания», положенного в основу концепции «справедливого рынка ценных бумаг». В нашей задаче отклонения $\{\delta_g(t)\}$ формируются прагматическими целями ухода от налогов, и, следовательно,

вероятна долговременная корреляция влияния предшествующих значений уровней временного ряда на текущие и последующие. Такой временной ряд может содержать фрактальную структуру, т.е. долговременные корреляции порождают фракталы, и закон распределения плотности вероятности этого ряда будет далеким от нормального. В этих условиях информационная ценность использования вероятностного критерия $P(\delta_g > \tilde{\delta})$, основанного на нормальном законе распределения, снижается.

Теперь остановимся на методах статистической оценки фрактальной размерности D в (4). По одному из определений Мандельброта [1], «фракталом называется структура, состоящая из частей, которые в каком-то смысле подобны целому», т.е. отдельные составленные части самоподобны. Фрактал есть аттрактор (предельное множество) правила, порождающего временной ряд (информационного процессора).

Одна из характеристик фрактальных объектов состоит в том, что они оставляют себе свою собственную размерность, будучи помещены в пространство размерности, большей, чем их фрактальная размерность. Например, временной ряд, графиком которого является линия на плоскости, т.е. в двухмерном пространстве, имеет собственную фрактальную размерность $D < 2$. Во фрактальном временном ряде положения точек определены корреляциями. Фрактальный объект заполняет пространство, куда он помещен, неравномерно, поскольку его части коррелированы (взаимосвязаны). Фрактальная размерность – это число, которое количественно описывает то, как объект заполняет пространство.

Чтобы определить фрактальную размерность, необходимо выяснить, каким образом объект группируется в единое целое в своем пространстве. Существует много способов расчета фрактальной размерности. Все они включают в себя подсчет объема или площади фрактальной формы и того, как она изменяется в масштабах в том случае, если этот объем увеличивается.

4. Формулировка концепции синтеза оптимального плана отбора налогоплательщиков для выездных проверок

Концепция. Критерий ранжирования налогоплательщиков при синтезе оптимального плана выездных проверок должен представлять собой агрегат (мультипликативную свертку), содержащую в себе числовые меры относительных отклонений $\{\delta_g\}_{t_0}$ моделируемого показателя от эталонной поверхности «обобщенной производственной функции» кластера налогоплательщиков по (1); числовую меру вероятности отклонений $\{\delta_g\}_{t_0}$ и коэффициент масштаба M_g налогоплательщика. Причем здесь возможны два случая:

а) закон распределения отклонений $f(\delta)$ близок к нормальному; здесь используется критерий ранжирования Ψ по (3) с аналитической либо численной оценкой вероятности $P(\delta_g > \tilde{\delta})$;

б) закон распределения отклонений $f(\delta)$ далек от нормального и характеризуется значительным «лептоэксцессом»; здесь используется фрактальная размерность D_g для оценки волатильности временного ряда остатков $\{\delta_g(t)\}$.

Приведенное утверждение показывает, что можно получить оценку искаженных данных при тестировании нейросетевого (НС)-отображения для группы сложных объектов.

Общим выводом из анализа вычислительных экспериментов является требование ограничения на степень искажения базы данных (БД), при которых нейросетевое (НС)-отображение (1) не теряет свойств устойчивости. Как показывает проведенный опыт, для этого должны быть выполнены следующие условия.

1. Построение НСМ должно быть возобновлено при поступлении новых данных от экономических объектов.

2. Общее число наблюдений в базе данных (БД), определяемое как произведение числа экономических объектов на число наблюдений каждого объекта, должно быть не менее чем в $5 \dots 10$ раз больше числа входных факторов n .

3. Число искаженных строк в базе данных (наблюдений) должно быть не более чем $80 \sim 90\%$ от их общего числа N .

4. Число искаженных столбцов в БД (входных факторов) должно быть не более чем $70 \sim 80\%$ от их общего числа $(n + 1)$.

5. Меры интенсивности искажений $\mu^{(k)}$ не должны превышать $(40 \dots 50)\%$ по отношению к невозмущенным данным. Перечисленные рекомендации 3, 4, 5 имеют эвристический характер, т.е. не дают практических рекомендаций, поскольку в реальных данных истинные значения $\langle \vec{x}_i, y_i \rangle, i = \overline{1, N}$ неизвестны, а значит, нельзя вычислить и числовую меру интенсивности возмущений $\mu^{(k)}$.

Однако для теоретического анализа полученные выводы позволяют причины неустойчивости НСМ «разложить по полочкам».

Заключение. Представленный в публикации вероятностно-фрактальный подход к ранжированию налогоплательщиков с использованием нейросетевой модели демонстрирует высокий потенциал для повышения эффективности налогового контроля. Учет двойственной природы больших отклонений, возникающих в данных, позволяет более адекватно интерпретировать результаты камерального анализа, минимизируя ошибки первого и второго рода. Вероятностный критерий и фрактальная размерность как меры риска обеспечивают более надежный и устойчивый механизм отбора объектов для выездных проверок, учитывающий как случайные, так и систематические искажения в отчетности. Разработанные методы способствуют созданию оптимальных планов налоговых проверок, повышая точность выявления нарушений и снижая нагрузки на контролирующие органы. В целом предложенный синтез вероятностных и фрактальных подходов открывает перспективы для дальнейших исследований и практического внедрения в задачи налогового мониторинга и анализа больших данных.

Библиографический список

1. Бирюков А. Н. Обобщение метода вложенных математических моделей на основе байесовского подхода к регуляризации задач нейросетевого моделирования налогового и финансового контроля // Экономика и управление. 2010. № 1. С. 85–89.
2. Горбатков С. А., Полупанов Д. В., Белолипецев И. И., Фархиева С. А. Нейросетевые методы отбора налогоплательщиков для проведения выездных проверок // Вестник евразийской науки. 2017. Т. 9, № 2. Статья 84. EDN YRQITH

3. Белолипец И. И. Построение оптимального плана выездных проверок на основе гибридной нейросетевой модели налогового контроля // Управление экономическими системами. 2013. № 4 (52). URL: <https://cyberleninka.ru/article/n/postroenie-optimalnogo-plana-vyezdnyh-proverok-na-osnove-gibridnoy-neyrosetevoy-modeli-nalogovogo-kontrolya> (дата обращения: 20.09.2025).

A PROBABILISTIC-FRACTAL APPROACH TO RANKING TAXPAYERS BASED ON A NEURAL NETWORK MODEL TO IMPROVE THE EFFECTIVENESS OF TAX CONTROL

Biryukov Alexander Nikolaevich

Sterlitamak branch of Ufa University of Science and Technology
49, Lenin Avenue, Sterlitamak, Republic of Bashkortostan, 453103, Russia
biryukov_str@mail.ru

Glushchenko Olga Ivanovna

Sterlitamak Polytechnic College
5, Socialist Str., Sterlitamak, Republic of Bashkortostan, 453104, Russia
olga.glushhenko@mail.ru

The article presents probabilistic-fractal approaches to the ranking of taxpayers based on a neural network model in order to increase the effectiveness of tax control. The practical significance of the approach lies in the creation of optimal tax control plans that increase the accuracy of detecting violations and reduce the burden on regulatory authorities. The proposed method opens up prospects for the development of neural network tax monitoring and big data analysis, taking into account the complex structure and nature of tax reporting.

Keywords: neural network model, tax return, probabilistic approach, fractal approach, taxpayer ranking, tax control

ОНТОЛОГИЧЕСКИЙ ПОДХОД К ПОСТРОЕНИЮ ЭКСПЕРТНОЙ СИСТЕМЫ УПРАВЛЕНИЯ РИСКАМИ БИЗНЕС-ПРОЦЕССОВ

Самойлова Катарина Вадимовна

Замятина Елена Борисовна

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

В работе рассматривается подход к построению экспертной системы поддержки принятия решений в управлении рисками бизнес-процессов. Для формализации знаний используется методология MASK, позволяющая описывать инциденты, причины, последствия и контрмеры, которые далее преобразуются в онтологию в формате OWL. Разработанная экспертная система выполняет семантический вывод: задает диагностические вопросы, выявляет цепочки причин и формирует рекомендации, включающие как технические, так и организационные меры.

Ключевые слова: экспертные системы, онтологии, управление рисками, поддержка принятия решений

Введение. Современные организации функционируют в условиях высокой неопределенности и подвержены множеству операционных рисков. Традиционные методы управления рисками включают идентификацию, анализ и выбор мер реагирования, однако на практике выбор конкретных контрмер часто осуществляется интуитивно и не всегда опирается на формализованные знания. Это снижает прозрачность и воспроизводимость принимаемых решений.

Экспертные системы позволяют формализовать опыт специалистов и применять его для поддержки принятия решений. При этом особую ценность представляют онтологические подходы, обеспечивающие структурированное представление знаний и возможность логического вывода. Использование онтологий делает работу экспертных систем более объяснимой и гибкой по сравнению с классическими системами на основе правил.

Цель данной работы – представить онтологический подход к построению экспертной системы для управления рисками бизнес-процессов. Основой служит методология MASK, позволяющая структурировать знания о рисках, их причинах и последствиях. Разработанная система демонстрируется на примере бизнес-процесса маркетинга, что подтверждает применимость предложенного подхода к реальным сценариям.

Существующие подходы к управлению рисками. Современные исследования активно применяют методы искусственного интеллекта. Aziz и Dowling [1] показали, что машинное обучение трансформирует управление финансовыми рисками: от оценки кредитоспособности до выявления мошенничества. Однако такие решения страдают от «черного ящика» моделей и слабой интеграции экспертных знаний. Qin [2] предложил интеллектуальную систему поддержки решений, объединяющую ML и case-based reasoning, но и здесь проблема объяснимости и согласованности с политикой организации остается открытой.

Онтологические подходы позволяют формализовать связи между событиями, рисками и последствиями. Так, Engelberg et al. [3] разработали онтологию распространения рисков в киберфизических системах. Однако их решение ограничивается аналитикой и не поддерживает выбор контрмер.

Систематический обзор Sánchez-García et al. [4] рассматривает таксономии контрмер на основе ISO/IEC 27005 [5] и NIST SP 800-53 [6]. Несмотря на структурированность каталогов, остается пробел: отсутствует формальная модель, связывающая причины рисков с мерами воздействия в конкретном контексте.

Таким образом, существующие решения – от классического риск-менеджмента до ИИ и онтологий – обеспечивают прогнозирование и анализ рисков, но редко поддерживают формализованный выбор контрмер. Наш подход восполняет этот пробел, связывая причины и последствия рисков с конкретными мерами в рамках онтологической экспертной системы.

Онтологическая экспертная система на основе методологии MASK. В качестве основы для разработки экспертной системы поддержки принятия решений выбран метод MASK [7]. Основная цель метода – извлечение и структурирование экспертного опыта для его накопления и повторного использования. MASK опирается на совместное моделирование с экспертами, благодаря чему модель отражает реальные практики и воспринимается специалистами как «зеркало знаний».

Ключевым результатом применения MASK является «книга знаний», или Knowledge Book, в которой фиксируются инциденты, причины их возникновения, последствия и меры реагирования. Такая структура позволяет формировать причинно-следственные цепочки, удобные как для анализа происшествий, так и для проектирования контрмер. Многоаспектное представление знаний в MASK включает описание задач, понятий, контекста, а также процессов и функций организации.

В предлагаемом подходе MASK используется как первый этап: на основе экспертных интервью и анализа документации формируется описание инцидентов, их причин, последствий и возможных действий. Далее эти элементы транслируются в онтологическую модель (OWL), где выделяются основные классы: Риск, Причина, Последствие, Контрмеры; отношение. Между ними задаются имеетПричину, приводитК, решается (рис. 1).




Рис. 1. Фрагмент онтологии

Экспертная система использует эту онтологию как базу знаний. Механизм вывода реализован через обход графа рисков и причин в глубину. Пользователь выбирает риск, система задает диагностические вопросы и отмечает подтвержденные причины. Если причина ведет к другому риску, анализ продолжается рекурсивно. Для каждой подтвержденной причины извлекаются связанные контрмеры.

Важной особенностью является наличие оболочки системы, обеспечивающей взаимодействие с пользователем. В демонстрационном прототипе реализован графический интерфейс (tkinter, Python), позволяющий выбирать риски и отвечать на диагностические вопросы. Итоговый вывод представляет собой список мер с пояснением их связи с рисками и причинами.

Кроме того, система поддерживает накопление нового знания: при появлении новой причины или меры она может быть добавлена в онтологию. Таким образом, экспертная система постепенно расширяется, превращаясь в динамическую базу знаний, где накапливается опыт организации.

Разработанная архитектура сочетает:

- MASK – для извлечения знаний;
- онтологию – для формализации и структурирования;
- экспертную систему – для логического вывода и поддержки решений.

Такой подход обеспечивает прозрачность, объяснимость и адаптивность при выборе контрмер, сохраняя возможность расширения и интеграции с международными стандартами.

Пример применения. В качестве примера рассмотрим бизнес-процесс маркетплейса, связанный с обработкой заказов. Типовой инцидент – доставка неправильного товара клиенту.

На первом шаге пользователь выбирает в системе риск «Доставлен неверный товар». Экспертная система автоматически извлекает из онтологии связанные причины. Каждая причина сопровождается диагностическим вопросом и способом ее проверки. Например:

- «Неверное размещение товара» → вопрос «Был ли товар размещен на верной полке мезонина?» (метод проверки: проверка данных в системе управления складами);
- «Сбой сканера» → вопрос «Работал ли сканер в момент сборки заказа?» (метод проверки: анализ логов устройства).




Рис. 2. Экран экспертной системы

Если проверка показывает, что сканер действительно не работал, система фиксирует эту причину как подтвержденную и продолжает анализ глубже. Она выявляет новые связанные риски, такие как «Заявка на ремонт не создана» («Была ли подана заявка на ремонт?») или «Устаревшее обучение» («Проходил ли сотрудник актуальное обучение работе со сканером?»).

В результате один локальный инцидент порождает цепочку взаимосвязанных причин: от сбоя оборудования до недостатков в организационных процедурах. На основе этих причин система формирует список контрмер, который включает как технические, так и управленческие меры:

- оперативное исправление ошибки и переотправка заказа клиенту;
- регистрация заявки на ремонт оборудования;
- аудит подготовки сотрудников и повторное обучение;
- дисциплинарные меры за нарушение протоколов.

Таким образом, экспертная система не только устраняет непосредственный сбой, но и выявляет глубинные организационные проблемы. Благодаря использованию MASK и онтологической структуры знаний рекомендации получаются прозрачными, объяснимыми и согласованными с корпоративной политикой.

Заключение. В работе предложен онтологический подход к построению экспертной системы для управления рисками бизнес-процессов. В основе метода лежит использование методологии MASK для извлечения и структурирования знаний об инцидентах, их причинах, последствиях и мерах реагирования. На основе этих данных формируется онтология, которая служит базой знаний экспертной системы.

Разработанная система выполняет семантический вывод: задает диагностические вопросы, выявляет причинно-следственные цепочки и подбирает контрмеры, включая как технические, так и организационные меры. Демонстрационный пример на бизнес-процессе маркетинга показал, что такой подход позволяет выявлять не только непосредственные технические сбои, но и глубинные организационные проблемы.

Библиографический список

1. Aziz S., Dowling M. AI and machine learning for risk management // SSRN Electronic Journal. 2018. 18 p. URL: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3201337
2. Qin H. Research on Machine Learning and Intelligent Decision Support System Based on Risk Prediction // Advances in Engineering Technology Research. 2023. Vol. 4, no. 1: Proceedings of the International Conference on Big Data Engineering and Intelligent Management Systems (ICBDEIMS 2023). P. 582–587. DOI [10.56028/aetr.4.1.582.2023](https://doi.org/10.56028/aetr.4.1.582.2023)
3. Engelberg S., Díaz M., Klenner M., van der Linden M. Towards an Ontology-Driven Approach for Process-Aware Risk Propagation // 20th International Conference on Business Process Management Workshops (BPM 2022 Workshops). Utrecht: CEUR-WS, 2023. P. 327–338.
4. Sánchez-García A., García-Galán J., Pimentel E. Countermeasures and their taxonomies for risk treatment in cybersecurity: A systematic literature review // Computers & Security. 2023. Vol. 130. Article 103179. DOI [10.1016/j.cose.2023.103179](https://doi.org/10.1016/j.cose.2023.103179)
5. Information technology – Security techniques – Information security risk management (ISO/IEC 27005:2018). International Organization for Standardization, ISO/IEC, 2018.
6. Security and Privacy Controls for Information Systems and Organizations (SP 800 53 Rev. 5). National Institute of Standards and Technology, 2020. DOI [10.6028/NIST.SP.800-53r5](https://doi.org/10.6028/NIST.SP.800-53r5)

ONTOLOGY-BASED EXPERT SYSTEM FOR BUSINESS PROCESS RISK MANAGEMENT

Samoilova Katarina

Zamyatina Elena

Perm State University

15, Bukireva Str., Perm, Russia, 614990

katarinasamoilova@yandex.ru

This paper presents an approach to building an expert system for decision support in business process risk management. The MASK methodology is applied for knowledge formalization, enabling the description of incidents, causes, consequences, and countermeasures, which are then transformed into an ontology in OWL format. The developed expert system performs semantic reasoning: it asks diagnostic questions, identifies causal chains, and generates recommendations that include both technical and organizational measures.

Keywords: expert systems, ontologies, risk management, decision support

АВТОМАТИЗИРОВАННАЯ СИСТЕМА ПРИВЛЕЧЕНИЯ КЛИЕНТА, ОСНОВАННАЯ НА НЕЙРОННЫХ СЕТЯХ: ОПРЕДЕЛЕНИЕ ГРУПП КОНКУРЕНТОВ И ЭФФЕКТИВНЫХ ПОСТОВ

Соколов Андрей Валерьевич

Автономная некоммерческая организация высшего образования «Университет Иннополис»
420500, Россия, г. Иннополис, ул. Университетская, д. 1
and.sokolov@innopolis.university

Шуткин Алексей Сергеевич

Автономная некоммерческая организация высшего образования «Университет Иннополис»
420500, Россия, г. Иннополис, ул. Университетская, д. 1
a.shutkin@innopolis.university

Хейфец Илья Игоревич

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

Исаева Екатерина Владимировна

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
ekaterinaisae@gmail.com

Соколов Артур Андреевич

Национальный исследовательский университет ИТМО
197101, Россия, г. Санкт-Петербург, проспект Кронверкский, д. 49а, лит. А
s0k0l0vartur@mail.ru

Бекларян Армен Левонович

Национальный исследовательский университет «Высшая школа экономики»
109028, Россия, г. Москва, Покровский бульвар, д. 11
abeklaryan@hse.ru

В статье представлено описание прототипа системы привлечения клиентов в социальной сети ВКонтакте. Система, основанная на нейронных сетях и состоящая из пяти модулей, позволяет практически полностью автоматизированно определять группы конкурентов предметной области, получать подписчиков конкурентов и сохранять данные, которые не представлены в API ВКонтакте, для аналитики и дальнейшей работы с ними, выявлять эффективные посты конкурентов для дальнейшей генерации на их основе эффективных продающих постов и эффективного постинга таргет-рекламы в ВКонтакте с высокой конверсией. После полной доработки и тестирования системы она будет масштабирована на другие социальные сети и мессенджеры. Каждый модуль выполняет свои задачи, для достижения которых используются различные архитектуры нейронных сетей и такие методы, как кластеризация, бинарная классификация, категориальная классификация и другие. Данная система является одной из первых моделей применения ИИ для привлечения клиента в социальных сетях.

Ключевые слова: нейросетевые технологии, автоматизированных маркетинг, привлечение клиента, бинарная классификация

Введение. Искусственный интеллект играет ключевую роль в современном маркетинге [1–3]. Выбор и заказ большинства товаров и услуг высокими темпами переходит в онлайн, в частности высокие темпы роста показывают социальные сети [4]. Так, социальная сеть ВКонтакте разработала сервис маркетплейса непосредственно внутри своей социальной сети. В свою очередь, компании выстраивают работу с клиентами напрямую в социальной сети.

Для того чтобы можно было работать с клиентами социальной сети, необходимо иметь этих клиентов в своей группе и каким-то образом их привлекать, что является нетривиальной задачей, так как о клиенте еще пока нет достаточной информации и данных. В своем роде привлечение новых клиентов можно сравнить с холодным стартом рекомендательных систем [5]. Необходимо, чтобы клиент совершил целевое действие, подписался на группу, но при этом отсутствуют данные, какие паттерны являются триггером для клиента.

Чтобы более эффективно спроектировать систему привлечения клиента, необходимо понимать жизненный цикл клиента. Более полную формализацию предложили Soumaya Lamrhari и др. [6]: жизненный цикл клиента – это привлечение, удержание и конверсия. Следует подчеркнуть, что последним двум посвящено множество исследований применения ИИ в этих направлениях, так как там уже имеются данные о клиентах в базах данных организации. Что касается привлечения клиента, напротив, существует большой пробел в исследованиях данной области.

В данной работе описывается проект автоматизированной системы привлечения клиента, основанной на нейронных сетях, состоящей из пяти модулей, и тесты на реальных данных по некоторым частям модулей системы. В частности, получение групп конкурентов предметной области модуля 1 с помощью бинарной классификации и определение эффективных постов модуля 3 с помощью линейной регрессии.

Данная работа подтверждает предположение, что, несмотря на ограниченные данные о новых клиентах, с помощью нейросетевых моделей можно эффективно определять целевую аудиторию и привлекать новых пользователей. Кроме того, завершенная система позволит почти полностью заменить маркетологов и тем самым поможет малому бизнесу избежать затрат, а среднему и крупному бизнесу более эффективно привлекать новых пользователей.

В работе исследуются сообщества ВКонтакте, связанные с доставкой еды, а также их посты. Основная цель работы – проектирование, обучение и тестирование нейросетевых и регрессионных моделей на этих данных, определение архитектуры нейросети с наивысшей точностью и выявление ключевых закономерностей. Конечный результат – нейросетевая система для классификации таких групп и регрессионная модель, оценивающая эффективность их постов.

Пятимодульная автоматизированная система привлечения клиента, основанная на нейронных сетях. Проект автоматизированной системы привлечения клиентов в социальной сети ВКонтакте представлен на рис. 1. Система представляет собой практически полностью автоматизированную модель привлечения клиентов в социальной сети ВКонтакте. В данном исследовании рассмотрены тесты и результаты, основанные на реальных данных из модулей 1 и 5, элемента 1.




Рис. 1. Архитектура системы

Модуль 1 представляет собой приложение, которое использует методы API ВКонтакте для доступа к социальной сети ВКонтакте и получает набор групп. Из этого набора выбирается небольшое подмножество (около 20–30 групп) и отправляется пользователю для ручной разметки. После ручной разметки подмножества наиболее релевантных групп на этом подмножестве обучаются нейронные сети LSTM, GRU и CNN. В конце своего жизненного цикла модуль 1 классифицирует оставшиеся группы исходного набора и возвращает список потенциальных целевых групп.

Модуль 2 отвечает за сбор данных (постов) из целевых групп с заданными интервалами с помощью API ВКонтакте.

Модуль 3 размечает данные о постах, используя метод регрессии целевой переменной. Целевой переменной публикации является прирост подписчиков группы за время публикации. Модуль 4 работает параллельно с модулями 2 и 3 и выявляет релевантных пользователей среди подписчиков групп интереса, используя статистическую оценку членства в наибольшем количестве таких групп.

Модуль 5 формирует наиболее привлекательный пост для групп релевантных подписчиков, используя дообученную модель LLM, и публикует его для целевой аудитории этих подписчиков. Обратите внимание, что целевая аудитория используется только для публикации рекламы, а не для сбора данных.

Классификация групп

Постановка задачи и формирование набора данных. Для выбора оптимальной архитектуры модели нейросети для классификации групп было проведено исследование на группах доставки еды. Через официальный API ВКонтакте [7] собраны данные о 10 657 сообществах, из которых 5414 относятся к целевому классу – группам, специализирующимся на услугах доставки еды. Для обеспечения сбалансированности выборки дополнительно были отобраны 5243 сообщества из иных тематик. Каждое наблюдение содержит название и описание группы, а также бинарный признак принадлежности к тематике доставки еды.

После удаления дубликатов и выбросов данные были перемешаны и разделены в пропорции 4:3:3 на обучающую, валидационную и тестовую выборки.

Методы и результаты. Для оценки качества классификации были последовательно обучены три архитектуры нейронных сетей: сверточная (CNN), рекуррентная с долгой краткосрочной памятью (LSTM) и с обновляемыми рекуррентными блоками (GRU). Согласно результатам экспериментов (рис. 2), архитектура LSTM продемонстрировала наилучшие показатели как на тестовой, так и на валидационной выборках. Сопоставимость точности на этих двух множествах указывает на отсутствие признаков переобучения.




Рис. 2. Точность классификации групп ВКонтакте при помощи CNN, LSTM и GRU

Регрессионная модель оценки эффективности постов

Постановка задачи и формирование набора данных. Для создания регрессионной модели выбраны следующие параметры: количество лайков (X1), комментариев (X2), репостов (X3) и просмотров (X4). Зависимая переменная (D1) – прирост числа подписчиков сообщества на следующий день после публикации.

Через API ВКонтакте собраны данные о 708 публикациях после удаления дубликатов, выбросов и записей с приростом подписчиков ниже медианы.

Анализ и результаты. Корреляция Пирсона показала наибольшую связь между лайками и приростом подписчиков (рис. 3).




Рис. 3. Корреляция Пирсона между параметрами модели

Был проведен анализ парной линейной регрессии между количеством лайков и изменением числа подписчиков. В исходной выборке преобладают посты с малым количеством лайков, которые слабо влияют на прирост подписчиков. Чтобы сосредоточиться на постах с высокой эффективностью, выделена ограниченная выборка (посты с количеством лайков более 1000) (рис. 4).




Рис. 4. Парная регрессии между лайками и изменении подписчиков с и без ограничений

Интерпретация. Модель, построенная на ограниченной выборке, продемонстрировала значительное улучшение качества модели, что подтверждает коэффициент детерминации (R^2), который для полной модели составил 0.1876 (табл. 1).

Таблица 1

Метрика	Полная модель	Ограниченная модель
Коэффициент детерминации	0.1876	0.6372
Среднеквадратичная ошибка	74.6	166

Ограниченная модель показала рост R^2 до 0.6372, что указывает на улучшение объясняющей способности. Однако среднеквадратичная ошибка увеличилась с 74.6 до 166, что свидетельствует о переобучении вследствие сокращения объема данных. Для повышения устойчивости модели требуется расширение релевантной выборки и продолжение экспериментов.

Заключение. В данной работе представлен прототип и первые результаты частичной реализации автоматизированной системы привлечения клиентов во ВКонтакте на основе современных методов машинного обучения, в частности нейросетевых и регрессионных моделей.

Результаты проведенных экспериментов подтвердили гипотезу о возможности эффективного привлечения новых пользователей даже в условиях ограниченности данных о потенциальных клиентах. Наилучшие результаты в классификации сообществ показала архитектура LSTM. С помощью парной линейной регрессии были выявлены значимые закономерности между активностью пользователей и приростом подписчиков. Особенно перспективным оказался подход с фильтрацией высокоэффективных постов, что позволило существенно повысить коэффициент детерминации регрессионной модели.

Предложенный в данной статье подход открывает новые возможности для автоматизации маркетинга в отечественных социальных сетях, особенно для малого и среднего бизнеса, снижая зависимость от человеческого фактора и позволяя точнее ориентироваться на потенциальную целевую аудиторию. Несмотря на ограниченность текущего этапа реализации, полученные результаты являются обоснованием для дальнейшего масштабирования и доработки системы, включая улучшение качества моделей, расширение выборок и проведение тестирования эффективности генерируемых рекламных сообщений в реальных условиях.

Таким образом, работа закладывает основу для создания интеллектуальных решений в области цифрового маркетинга, способных автономно выполнять функции аналитика, таргетолога и контент-менеджера в единой архитектуре.

Библиографический список

1. Romic J. Digital Marketing and Artificial Intelligence // Reference Module in Social Sciences. Academic Press, 2026. С. 98–102.
2. Соколов А. В. и др. Применение искусственного интеллекта для привлечения клиентов в социальных сетях: обзор российского и зарубежного опыта // Вестник Пермского университета. Математика. Механика. Информатика. 2025. № 1 (68). С. 118–144.
3. Рабчевский А. Н., Ясницкий Л. Н., Заякин В. С. Сравнение методов выявления ролей пользователей в онлайн-социальных сетях // Прикладная математика и вопросы управления. 2021. № 2. С. 93–111.
4. Статистика соцсетей в мире (2025). URL: <https://inclient.ru/global-social-networks-stats/> (дата обращения: 21.09.2025).
5. Соколов А. В. и др. Теоретические и практические аспекты построения рекомендательных моделей: типология, архитектура и направления проектирования // Вестник Пермского университета. Математика. Механика. Информатика. 2024. Т. 3, № 3 (66). С. 64–77.
6. Lamrhari S. et al. A social CRM analytic framework for improving customer retention, acquisition, and conversion // Technological Forecasting and Social Change. 2022. Vol. 174. Article 121275. DOI [10.1016/j.techfore.2021.121275](https://doi.org/10.1016/j.techfore.2021.121275)
7. Описание методов API // VK для разработчиков. URL: <https://dev.vk.com/ru/method> (дата обращения: 21.09.2025).

AUTOMATED CUSTOMER ACQUISITION SYSTEM BASED ON NEURAL NETWORKS: IDENTIFYING COMPETITOR GROUPS AND EFFECTIVE POSTS

Andrey V. Sokolov

Autonomous non-profit organisation of higher education 'Innopolis University'
1, Universitetskaya Str., Innopolis, Russia, 420500
and.sokolov@innopolis.university

Alexey S. Shutkin

Autonomous non-profit organisation of higher education 'Innopolis University',
1, Universitetskaya Str., Innopolis, Russia, 420500
a.shutkin@innopolis.university

Ilya I. Heifets

Perm State University
15, Bukireva Str., Perm, Russia, 614990
kheyfetz@psu.ru

Ekaterina Isaeva

Perm State University
15, Bukireva Str., Perm, Russia, 614990
ekaterinaisae@gmail.com

Arthur A. Sokolov

ITMO National Research University
Bldg A, 49, Kronverksky Pr., St. Petersburg, Russia, 197101
s0k0l0vartur@mail.ru

Armen L. Beklaryan

HSE University
11, Pokrovsky Boulevard, Moscow, Russia, 109028
abeklaryan@hse.ru

The article presents a description of a prototype system for attracting customers on the VKontakte social network. The system, based on neural networks and consisting of five modules, allows you to almost automatically identify groups of competitors in a specific domain, obtain competitors' subscribers, and store data which are not represented in the VKontakte API for analytics and further work with them, identify effective posts by competitors for further generation of effective sales posts and effective posting of targeted advertising on VKontakte with high conversion rates. After complete refinement and testing of the system, it will be scaled to other social networks and messengers. Each module performs its own tasks, for which various neural network architectures and methods such as clustering, binary classification, categorical classification and others are used. This system is one of the first models of AI application for attracting customers on social networks.

Keywords: neural network technologies, automated marketing, customer acquisition, binary classification

КЛАССИФИКАЦИЯ ЗВУКОВ ГОРОДСКОЙ СРЕДЫ НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ

Белаш Валерия Андреевна

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
belashva@yandex.ru

В статье представлены результаты разработки и сравнения методов глубокого обучения для автоматической классификации звуков городской среды. Были реализованы и протестированы три архитектуры нейронных сетей: рекуррентная сеть для обработки сырых аудиоданных, рекуррентная сеть для классификации мел-спектрограмм и сверточная нейросеть. Рассмотрено практическое приложение автоматической классификации звуков городской среды для развития умных городов.

Ключевые слова: нейросетевые технологии, классификация звуков, мел-спектрограммы, городская среда, умный город, акустический мониторинг

Введение. Современные города представляют собой сложные динамические организмы, чья жизнедеятельность генерирует непрерывный и разнообразный акустический поток. Этот поток, или, по-другому, звуковой ландшафт, является не просто «фоном города», но и критически важным источником информации о функциональном состоянии городской инфраструктуры, событиях социальной активности, транспортных потоках, возникающих аномалиях и проблемах. Исторически сложились несколько традиционных подходов к его изучению.

Акустико-инженерный подход фокусируется на измерении уровня звукового давления (в дБ) и создании шумовых карт, рассматривая звук как физический загрязнитель [1]. Перцептивно-психологический подход [2], основанный работами Р. Мюррея Шафера и проекта World Soundscape Project, смещает акцент с громкости на восприятие, вводя концепции «саундмарков» (уникальных звуков места) и «звуковых прогулок». Социокультурный подход развивает эти идеи, исследуя, как звук отражает инфраструктуру и идентичность места [3].

Однако эти традиционные подходы, опирающиеся в первую очередь на ручной аудит, точечные замеры и зашумленные пороговые методы, оказываются несостоятельными перед лицом масштаба, непрерывности и сложности данных современного развивающегося мегаполиса. Их запаздывание и неспособность выявлять сложные паттерны в реальном времени формируют необходимость для разработки автоматизированного анализа на основе нейросетевых технологий.

Автоматическая классификация звуковых событий представляет значительный интерес для развития умных городов и улучшения качества жизни населения. В данной работе исследуются современные подходы к классификации звуков городской, и проводится сравнительный анализ архитектур нейронных сетей. Конечный результат – нейросеть, способная распознавать и классифицировать звуки городского ландшафта.

Набор данных и его обработка. При проведении данной работы использовался набор данных «UrbanSound8K», который содержит 8732 аудиозаписи. Все записи распределены по десяти классам (звуки кондиционерных систем, автомобильных гудков, детских игр, лая собак, строительных работ, шума транспорта, выстрелов, отбойного молотка, тревожных сирен и уличной музыки). Продолжительность записей варьируется от 0,3 до 4,0 секунд. Все аудиозаписи представлены в формате *WAV с частотой дискретизации 44,1 кГц и разрешением 16 бит. Для обеспечения работы с аудиоданными специально был разработан класс, обеспечивающий их динамическую загрузку и нормализацию амплитуды сигнала. Это необходимо для обеспечения согласованности и качества входных данных для последующей обработки [4].

Проектирование архитектуры нейросетей, их обучение и применение. В качестве первой архитектуры была спроектирована рекуррентный классификатор исходного сырого звукового сигнала (рис. 1). Данная архитектура, обрабатывающая звук как временной ряд напрямую, достигла точности всего 37,1% на валидационной выборке. Низкое качество работы модели объясняется высокой чувствительностью к шумам и помехам, что характерно для методов, работающих с сырым звуковым сигналом [5].




Рис. 1. Архитектура рекуррентного классификатора

Для построения надежных и устойчивых к переобучению моделей рекомендуется использовать другое представление аудиоданных – спектрограмм [6]. Поэтому при построении второй архитектуры было решено изменить рекуррентный классификатор так, чтобы вместо сырого сигнала нейронная сеть обрабатывала мел-спектрограмму (рис. 2). Рассмотрим процесс построения мел-спектрограмм. Первоначально исходный сигнал разделяется на перекрывающиеся временные интервалы, к каждому из которых применяется фильтрация чаще всего с применением оконной функции на основе косинуса. Затем к полученному отфильтрованному сигналу применяется дискретное преобразование Фурье, на основе которого извлекаются спектральные характеристики. Для соответствия восприятию человеческого слуха эти спектральные компоненты логарифмически трансформируются и переводятся в шкалу Мел [7] – частотную шкалу, имитирующую нелинейную чувствительность уха к звуковым частотам.

Благодаря использованию частотно-временных представлений звука, вторая нейросеть достигла точности 79,5% на валидационном наборе данных. Такое существенное улучшение качества (более чем двукратное) подтверждает эффективность перехода к спектральному представлению данных.




Рис. 2. Пример преобразования сырого сигнала в мел-спектрограмму

Мел-спектрограммы обладают ярко выраженными визуальными структурами, и при некоторой практике даже человек, не обладающий специальными знаниями в акустике, способен «на глаз» определить тип звука по его спектрограмме. Это открывает возможность решить задачу классификацию звука на основе сверточной нейронной сети как классификацию изображений. Так, третьей архитектурой (рис. 3) была реализована десятислойная сверточная сеть [8], которая достигла показателя точности 86,8% на валидационной выборке.

Сравнивая модели, заметим, что переход от работы с сырым сигналом к спектральному представлению и далее к сложным сверточным архитектурам позволяет заметно улучшить точность классификации. Наилучшая модель (сверточная) показала точность в 87%, что делает ее пригодной для практического применения в системах автоматического мониторинга городской среды.

Детальный анализ матрицы ошибок (рис. 4) показал, что наибольшее количество ошибок классификации приходится на пары звуковых классов, обладающих схожими спектральными характеристиками. В частности, третья модель часто путает звуки сверления и шума обойного молотка, оба характеризуются импульсным, широкополосным спектром и содержат перекрывающиеся гармонические структуры, что затрудняет их различие. Также значительное число

ошибок наблюдается при классификации звуков шума транспорта и кондиционерных систем: оба источника генерируют устойчивую низкочастотную энергию и демонстрируют минимальную спектральную динамику.




Рис. 3. Архитектура сверточной нейросети




Рис. 4. Матрицы ошибок реализованных нейросетей

Все архитектуры были реализованы с использованием фреймворка глубокого обучения PyTorch с модулем обработки аудио TorchAudio. Все вычисления проводились использованием GPU ускорения через CUDA для обеспечения эффективного обучения моделей.

Заключение. Проведенное исследование продемонстрировало высокую эффективность применения методов глубокого обучения для решения задачи автоматической классификации звуков городской среды. Было экспериментально

доказано, что переход от обработки сырого аудиосигнала к анализу мел-спектрограмм позволяет существенно повысить точность распознавания: с 37,1% до 79,5%. Наилучший результат был достигнут с использованием десятислойной сверточной нейронной сети, которая рассматривает спектрограммы как изображения и выявляет в них пространственно-временные закономерности. Это значительно увеличивает устойчивость моделей к вариациям громкости, наличию шумов и изменению тембральных характеристик.

Разработанная нейросеть обладает значительным практическим потенциалом для внедрения в инфраструктуру умных городов. Она может быть использована для: мониторинга шумового загрязнения в режиме реального времени, автоматического обнаружения акустических аномалий и чрезвычайных ситуаций, оптимизации городского планирования, создания интеллектуальных систем безопасности. В перспективе исследование следует направить на разработку мультимодальных архитектур (т.е. с обработкой аудио и видео), адаптацию алгоритмов к работе в условиях сильных шумовых помех.

Библиографический список

1. Berglund B., Lindvall T., Schwela D. H. Guidelines for Community Noise. World Health Organization. URL: <https://www.who.int/>
2. The World Soundscape Project. Simon Fraser University / R. Murray Schafer, Barry Truax et al. URL: <https://www.sfu.ca/>
3. Майорова К. Исследования звука и города: к акустическому повороту в урбанистике. URL: <https://publications.hse.ru/>
4. Лайонс Р. Г. Цифровая обработка сигналов / пер. с англ. 2-е изд. М.: БИНОМ. Лаборатория знаний, 2006. 656 с.
5. Salamon J., Bello J. P. Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification // IEEE Signal Processing Letters. 2017. Vol. 24, no. 3. P. 279–283. DOI 10.1109/LSP.2017.2657381
6. Stevens S. S., Volkman J., Newman E. B. A Scale for the Measurement of the Psychological Magnitude Pitch // Journal of the Acoustical Society of America. 1937. Vol. 8, no. 3. P. 185–190. DOI 10.1121/1.1915893
7. Logan B. Mel Frequency Cepstral Coefficients for Music Modeling // Proceedings of the International Symposium on Music Information Retrieval (ISMIR). 2000. P. 1–11.
8. Kong Q., Cao Y., Iqbal T., Wang Y., Wang W., Plumbley M. D. PANNs: Large-Scale Pretrained Audio Neural Networks for Audio Pattern Recognition. URL: <https://arxiv.org/pdf/1912.10211>

CLASSIFICATION OF URBAN SOUNDSCAPES BASED ON DEEP LEARNING

Valeria A. Belash

HSE University

38, Studencheskaya Str., Perm, Russia, 614070

belashva@yandex.ru

The article presents the results of developing and comparing deep learning methods for the automatic classification of urban sounds. Three neural network architectures were implemented and tested: a recurrent network for processing raw audio signals, a recurrent network for classifying mel-spectrograms, and a convolutional neural network. Practical applications of automatic urban sound classification for the development of smart cities are proposed.

Keywords: neural network technologies, sound classification, mel-spectrograms, urban environment, smart city, acoustic monitoring

ПРОГНОЗИРОВАНИЕ ЦЕНЫ КУПЛИ-ПРОДАЖИ ПОДЕРЖАННЫХ ТРАНСПОРТНЫХ СРЕДСТВ В УСЛОВИЯХ ОТСУТСТВИЯ ЦЕН СДЕЛОК

Мезин Евгений Александрович

Пермский национальный исследовательский политехнический университет
614990, Россия, Пермский край, г. Пермь, Комсомольский проспект, д. 29
ea.mezin@gmail.com

В статье сформулирована проблема и предложено модельное решение расчета наиболее вероятных цен сделок купли-продажи подержанных автомобилей при условии доступности цен предложений об их продаже и при отсутствии подтвержденных цен реальных сделок.

Ключевые слова: организационные системы, машинное обучение, экспертные суждения, подержанные транспортные средства, прогнозирование стоимости автомобилей

Введение. Массовая оценка подержанных транспортных средств – важная задача для финансовых организаций, страховщиков, государства и участников рынка. Реальную стоимость определяет цена сделки, тогда как цена предложения отражает лишь ожидания продавца и обычно оказывается выше из-за торга, скидок или условий программ. Использование только цен объявлений ведет к завышению оценок, искажению статистики и рискам: завышенные ожидания у продавцов, ошибки в расчете ликвидности залогов и кредитных рисков у банков, некорректная страховая стоимость и искажения налоговой базы. Поэтому исследования в этой области направлены на поиск методов приближения данных объявлений к реальным ценам сделок, что обеспечивает объективность информации и прозрачность рынка.

Степень проработанности проблемы. В настоящее время предметом исследований остаются методы оценивания стоимости автомобилей.

Патент JP2024011981A (Honda) описывает ансамбль моделей машинного обучения с весовыми коэффициентами, что повышает точность, но без экспертной обратной связи и переобучения [1]. Патент US20210264483A1 предлагает обновление оценки с учетом пользовательских данных и предпочтений, однако без анализа реальных цен сделок результаты чувствительны к шуму [2]. В патенте RU2681698C2 используется дерево решений: метод прост и прозрачен, но точность ограничена, отсутствует адаптивность и аппроксимация к рыночным ценам [3]. Патент US2022284460A1 интегрирует данные из разных источников, но также не имеет механизмов обратной связи и постоянного обновления [4]. Патент CN117911057A предусматривает корректировку оператором, полезную при ошибках модели, однако без интеграции в процесс обучения [5].

P. Ponmalar, A. Christinal представили обзор методов ML для оценки цен подержанных автомобилей: Random Forest, XGBoost, деревья решений, линейные и гибридные модели [6]. S. K. Satapathy сравнил XGBoost и Random Forest

на датасете с характеристиками авто (год выпуска, пробег, топливо и др.), где XGBoost показал ~92%, когда RF ~90% точности [7]. В. Сui и соавторы проанализировали XGBoost и LightGBM на большом массиве данных, выявив различия в эффективности [8]. И. Е. Алексеева, А. О. Алексеев, Е. А. Мезин предложили разделение задачи на классификацию и последующую оценку внутри когорты. Такой подход улучшает результаты независимо от выбранного метода (регрессия, деревья, CatBoost) [9].

Во всех рассмотренных патентах и научных статьях прослеживается единая логика: разработчики и исследователи ориентируются на анализ ценовых предложений, представленных в объявлениях о продаже автомобилей. Используемые алгоритмы – от простых деревьев решений и регрессионных моделей до ансамблей на базе Random Forest, XGBoost и LightGBM – демонстрируют хорошую предсказательную силу именно в рамках этих датасетов. Тем не менее все эти решения ограничены тем, что фактически работают с ценой предложения – той, что заявлена в объявлении, а не с результатом заключенной сделки. В ряде патентов предусматривается участие оператора для ручной корректировки модели или проверки расчетов, однако это остается локальным вмешательством, не встроенным в непрерывный цикл адаптивного обучения. Таким образом, системы не приближаются к реальной рыночной цене, которая формируется в процессе переговоров и заключения сделки с учетом торга, скидок и скрытых условий.

Именно разрыв между заявленной ценой предложения и итоговой ценой сделки остается критическим ограничением как для патентованных решений, так и для академических исследований. Несмотря на значительные успехи в области машинного обучения и применения ансамблевых методов, практическая применимость таких моделей в массовой рыночной оценке ограничена отсутствием данных о фактических транзакциях. Это делает дальнейшее развитие в направлении интеграции расчета наиболее вероятных цен предложений и вторичного обучения для их аппроксимации цен к реальному рынку ключевым вектором для повышения точности и релевантности систем автоматизированной оценки.

Возможные подходы, обеспечивающие корректировку цен предложений **к рыночным значениям**. Когда данные о реальных сделках недоступны, применяются косвенные методы аппроксимации рыночной цены: анализ времени жизни объявлений, применение справочников и индексов, поиск реальных данных о сделках, экспертные суждения.

Анализ времени жизни объявлений. Метод основан на сопоставлении цены и срока размещения: быстрое снятие может указывать на продажу, долгий листинг – на завышенную цену. Преимущество – использование открытых данных; ограничение – снятие объявления не всегда означает сделку, а итоговая цена могла измениться при торге [10].

Справочники и индексы. В оценке применяются агрегированные данные дилеров, аукционов, специализированные справочники (аналогично справочникам Лейфера для недвижимости). Они задают корректирующие коэффициенты («торг», «опт», ликвидационная стоимость и др.), однако такие справочники часто устаревают и охватывают не весь рынок [11].

Данные о сделках. Наиболее достоверный источник, позволяющий обучать алгоритмы на реальных ценах. Однако такие данные закрыты, разрозненны (авто-салоны, госреестры) и могут искажаться в целях налоговой и кредитной оптимизации. Сбор таких данных требует значительных ресурсов и не всегда возможен.

Экспертные суждения. Наиболее доступный способ постоянной корректировки, обеспечивающий статистическую ценность данных. Ограничения: высокая себестоимость и необходимость регулярного привлечения экспертов. Автор сталкивался с такими проблемами при НИОКР по разработке прототипа системы оценки транспортных средств [12].

Все методы имеют ограничения: время жизни объявлений не отражает фактической сделки, справочники устаревают, доступ к сделкам ограничен. На практике наиболее применимым инструментом остается экспертная разметка, требующая постоянного и массового сбора данных для объективной картины рынка.

Предлагаемый способ оценки транспортных средств. Для решения задачи определения наиболее вероятной цены сделки с подержанным автомобилем предлагается организационный способ, включающий три последовательных этапа. На первых двух этапах решается задача получения максимально точной цены предложения. Сначала определяется принадлежность автомобиля к определенной когорте транспортных средств (марка, модель, модификация), что позволяет задать базовую цену. Далее проводится анализ ключевых характеристик: года выпуска, пробега, цвета, числа владельцев и других параметров, влияющих на индивидуальное отклонение от базового значения. На третьем этапе производится аппроксимация цены объявления к наиболее вероятной цене сделки с использованием коэффициента торга, формируемого на основе экспертных суждений (рис. 1). Такой подход обеспечивает согласование результатов автоматической оценки с рыночной действительностью и позволяет преодолеть ограничение большинства существующих систем, работающих исключительно с ценами предложений [9].




Рис. 1. Способ оценивания подержанных автомобилей

Организационная система реализует взаимодействие трех ключевых элементов: цифрового приложения для оценки транспортных средств, эксперта-дилера и конечного предложения о продаже автомобиля. Приложение выполняет функцию центра обработки данных, получая информацию из внешних источни-

ков и рассчитывая вероятные цены предложений и сделок. Эксперт-дилер выступает посредником между системой и рынком: он подтверждает или уточняет расчетные значения и в обмен предоставляет собственные экспертные данные. Его мотивация заключается в доступе к целевым транспортным средствам, оцененным системой «ниже рынка», что открывает возможность дополнительного дохода. Завершающим элементом является предложение о продаже, которое одновременно формирует рынок и служит вознаграждением эксперту за предоставленные суждения. Таким образом, система дополняет базу данных недостающей информацией о реальных ценах сделок и формирует самообучающийся алгоритм, ориентированный на минимизацию ошибок оценки и приближение результатов к реальной рыночной стоимости (рис. 2).




Рис. 2. Схема организационного взаимодействия приложения оценки и эксперта

Таким образом, возможно построить организационную систему по разметке базы данных недостающей информацией о ценах реальных сделок по купле-продаже транспортных средств, предоставляя эксперту в качестве платы за его знания информацию о целевых сделках, на которых возможно получить доход от взаимодействия с продавцом автомобиля. При этом целевая функция системы в виде количества ошибок оценки должна стремиться к нулю.

Заключение. Проведенный анализ показал, что существующие научные и патентные разработки в сфере оценки подержанных автомобилей ориентированы преимущественно на цены объявлений. Даже с применением современных алгоритмов машинного обучения (дерева решений, XGBoost, LightGBM, CatBoost) прогнозируется стоимость публикации, а не сделки, что ведет к систематическому завышению результатов и снижает практическую ценность таких систем.

Методы аппроксимации цен предложений – анализ времени жизни объявлений, справочники и частичные данные о сделках – обладают ограниченной точностью и устойчивостью. В условиях закрытости информации о реальных транзакциях единственным практическим инструментом остаётся экспертная разметка, требующая значительных ресурсов.

Актуальной задачей становится создание организационной системы, объединяющей интеллектуальные алгоритмы оценки с экспертной обратной связью. Такая система должна быть адаптивной и самообучающейся, что позволит приближать цены объявлений к рыночным значениям, формировать объективную информацию и снижать риски участников рынка.

Библиографический список

1. JP 2024-011981 A (Honda) – Vehicle evaluation system. URL: <https://patents.google.com/patent/JP2024011981A>
2. US 2021/0264483 A1 – Object evaluation update system. URL: <https://patents.google.com/patent/US20210264483A1>
3. RU 2681698 C2 – Автоматизированная система оценки стоимости автомобиля. URL: <https://patents.google.com/patent/RU2681698C2>
4. US 2022/284460 A1 – Aggregated data evaluation system. URL: <https://patents.google.com/patent/US2022284460A1>
5. CN 117911057 A – Operator-assisted correction system. URL: <https://patents.google.com/patent/CN117911057A>
6. Ponmalar P., Christinal A. Review on the Pre-owned Car Price Determination using Machine Learning Approaches // 2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS). Trichy, 2022. P. 274–278. DOI [ICAISS55157.2022.10010958](https://doi.org/10.1109/ICAISS55157.2022.10010958)
7. Satapathy S. K., Vala R., Virpariya S. An Automated Car Price Prediction System Using Effective Machine Learning Techniques // 2022 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES). Greater Noida, 2022. P. 402–408, DOI [10.1109/CISES54857.2022.9844350](https://doi.org/10.1109/CISES54857.2022.9844350)
8. Cui B., Ye Z., Zhao H., Renqing Z., Meng L., Yang Y. Used Car Price Prediction Based on the Iterative Framework of XGBoost+LightGBM // Electronics. 2022. Vol. 11, no. 18. Article 2932. DOI [10.3390/electronics11182932](https://doi.org/10.3390/electronics11182932)
9. Алексеева И. Е., Мезин Е. А., Алексеев А. О. Декомпозиция ценообразующих факторов на основе статистического анализа экспертных оценок их значимости // Вестник Южно-Уральского государственного университета. Серия «Компьютерные технологии, управление, радиоэлектроника». 2025. Т. 25, № 3. С. 53–63.
10. Demiriz A., Şen S., Gökçeğöz F. (2013). Analyzing Classified Listings at an E-Commerce Site by Using Survival Analysis // European Conference in Technology and Society (EuroTecS). URL: <https://scispace.com/pdf/analyzing-classified-listings-at-an-e-commerce-site-by-using-2w9saw19tt.pdf>
11. Справочник оценщика машин и оборудования-2023. URL: <https://inform-ocenka.ru/shop/>
12. Мезин Е. А. Разработка и тестирование прототипа системы оценки стоимости транспортных средств на основе анализа Big Data с учетом факторов нестабильности рынков для автоматизации деятельности финансовых институтов: отчет о НИОКР // Фонд содействия развитию малых форм предприятий в научно-технической сфере. Рег. № ЕГИСУ НИОКТР 223101200012-2. Пермь: Мезекс. Информационные системы. 157 с.

FORECASTING TRANSACTION PRICES OF USED VEHICLES IN THE ABSENCE OF DEAL DATA

Evgenii A. Mezin

Perm National Research Polytechnic University
29, Komsomolsky Ave., Perm, Russia, 614990
ea.mezin@gmail.com

Mass valuation of used vehicles is a significant task for financial institutions, insurance companies, government authorities, and market participants. The actual market value is determined by the transaction price, whereas the offer price reflects only the seller's expectations and is typically higher due to bargaining, discounts, or special programs. Reliance solely on offer prices leads to inflated valuations, distorted statistics, and increased risks: unrealistic expectations for sellers, errors in liquidity assessment and credit risk for banks, incorrect insurance valuations, and miscalculations in the tax base. Consequently, research in this field focuses on developing methods to approximate offer data to actual transaction prices, thereby ensuring objective market information and market transparency.

Keywords: organizational systems, machine learning, expert judgments, used vehicles, car price forecasting

КОНЦЕПЦИЯ АССИСТЕНТА ОЦЕНЩИКА НА ОСНОВЕ ТЕХНОЛОГИИ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Помулев Александр Александрович

Финансовый университет при Правительстве Российской Федерации
125167, Россия, Москва, пр-кт Ленинградский, д. 49/2
me@pomulev.ru

В статье рассматривается концепция разработки программного ассистента для специалистов-оценщиков, основанного на возможностях генеративного искусственного интеллекта (Gen AI). Актуальность работы обусловлена необходимостью обработки больших объемов структурированных и неструктурированных данных, а также минимизации субъективного фактора в процессе оценки. Предлагается использование большой языковой модели (LLM) GigaChat (Giga-chat-2-max) в качестве ядра системы. Описываются постановка задачи, формирование набора данных для обучения и настройки модели, ключевой функционал ассистента и проектирование его архитектуры.

Ключевые слова: генеративный искусственный интеллект, большая языковая модель, оценка стоимости, оценочная деятельность, помощник оценщика

Введение. Профессиональная деятельность оценщика сопряжена с комплексным анализом значительных массивов разнородной информации: рыночных данных, технической документации, нормативно-правовых актов, новостных сообщений и аналитических отчетов. Традиционно этот процесс требует больших временных затрат и обладает высокой степенью субъективности, так как зависит от опыта и экспертного мнения конкретного специалиста. Современные профессиональные оценщики все чаще используют технологии ИИ для автоматизации рутинных задач и повышения точности. Большие языковые модели (LLM) позволяют создавать интеллектуальных «ассистентов», способных анализировать большие объемы данных и генерировать текстовые отчеты. ИИ-ассистент оценщика активов и бизнеса должен уметь автоматически собирать информацию об объекте оценки, проводить макроэкономический и рыночный анализ, подбирать аналогичные объекты, вычислять стоимость, оценивать риски, генерировать отчет, консультировать по законодательной и нормативной базе оценочной деятельности. Эти функции обеспечивают ускорение и стандартизацию оценочных процедур, сохраняя при этом экспертный контроль.

Целью данной работы является разработка концепции ассистента оценщика стоимости бизнеса, использующего в своей основе LLM GigaChat (Giga-chat-2-max). Интеллектуальный ассистент не заменит эксперта, а усилит его способности, взяв на себя рутинные операции и предоставив оценщику аргументированные предложения и выводы.

Обзор готовых решений на рынке. На рынке уже появились несколько платформ, претендующих на роль ИИ-ассистента для оценщика, однако в основном для оценки объектов недвижимости. В табл. 1 приведено краткое сравнение некоторых из них.

Анализ решений ИИ-помощников оценки активов

Наименование решения	Основной функционал	Преимущество	Недостаток
PropMix Appraisal Assistant [1]	Интегрирован с платформой Profet.ai. Использует LLM для консультации по регламентам, автоматизирует задачи подбора аналогов, подготовки черновика расчетов	Интеграция с отраслевыми стандартами, обучение новичков, ускорение работы и улучшение качества работы	Ориентация на рынок США и местные нормативные документы. Требуется обучения специалистов для работы
HouseCanary CanaryAI [2]	Генеративный AI-ассистент для рынка жилья. Отвечает на запросы по объектам-аналогам на базе 136 миллионов объектов, помогает с анализом рынка на основе аналитических данных	Большая база данных, аналитика рынка. Мгновенные ответы «на естественном языке». Предназначен для инвесторов, риелторов и кредиторов	Специализация на рынке жилой недвижимости в США, коммерческий сегмент поддерживаются с ограничениями
HouseStack LILA / Appraisal Pro [3]	Генеративный помощник для запросов по недвижимости, AI-анализ отчета с рыночными трендами, автоматизация составления отчетов	Обработка запросов на основе огромной базы (1 млрд объектов), быстрая генерация отчета по анализу рынка, упрощение формирования отчета	Мультипродуктовая экосистема, может быть сложна в интеграции. Применима для рынка Канады и США, локализация ограничена
Automax AI [4]	Помощник оценщика для подбора аналогов по объектам недвижимости, анализ данных, автозаполнение отчетов. Генерирует отчеты (с расчетами по используемым данным)	Быстрое определение аналогов, встроенный анализ данных. Полное соответствие американскому стандарту USPAP, шифрование данных, отсутствие хранения частных данных. Автоматизированное заполнение отчетов (UAD) с учетом всех расчетов	Ориентация на американский рынок, фокус на структурированных данных; менее развит поиск и качественный анализ текстовой информации
Залоговая машина Сбера	Оценка активов для целей залога, подбор аналогов и формирование заключения об оценке залога	Быстрый подбор аналогов по объектам жилой и коммерческой недвижимости, расчет стоимости на базе совершенных сделок Сбера на российском рынке с использованием собственных ML моделей	Ориентирована для внутреннего использования залоговыми специалистами, не поддерживает функционал формирования отчетов по требованиям ФСО
Сервис онлайн оценки SRG [5]	Автоматизация оценки недвижимости	Автоматическая оценка объектов недвижимости (жилые квартиры, апартаменты и объекты ИЖС) на базе собственных ML-моделей	Не адаптирована для генерации полноценного отчета об оценке

Источник: разработано автором.

Сервис Cyndx Valer [6] предлагает AI-инструменты для бизнес-оценки с использованием метода дисконтированных денежных потоков, сравнительного подхода по данным публичных и частных аналогов и т.д. Однако решение ориентировано скорее на инвесторов, чем на оценщиков бизнеса и базируется на данных иностранных компаний. На российском рынке появляются решения на основе технологии GPT. Сервис Московской биржи Fingpt [7] для предоставления финансовой отчетности по публичным компаниям, анализа макроэкономической и отраслевой информации из официальных источников, что существенно упрощает работу с внешними источниками данных. Также сервис больше ориентирован на инвесторов, чем на оценщиков.

В целом можно сделать вывод, что готовых ассистентов профессионального оценщика стоимости бизнеса на рынке нет.

Постановка задачи и формирование набора данных. Основная задача заключается в создании интеллектуальной системы, которая на основе входных параметров объекта оценки и контекстного запроса оценщика способна:

- 1) извлекать и анализировать релевантную информацию из предоставленных документов и внешних источников для корректной идентификации объекта оценки и необходимых данных для его оценки;
- 2) помогать принять решение о выборе подходов и методов стоимостной оценки с учетом поставленных целей и задач;
- 3) определять стоимость бизнеса с использованием доходного, сравнительного и затратного подходов;
- 4) согласовывать результаты оценки с выбранными подходами;
- 5) генерировать текстовые фрагменты отчетов (описания, аналитические разделы, заключения) в соответствии с требованиями стандартов оценки (ФСО [8]);
- 6) отвечать на вопросы оценщика в рамках предметной области, объясняя методологию и термины.

Решение задачи разбивается на этапы: семантическое понимание запроса, поиск и обработка данных, логический вывод и генерация ответа.

Формирование набора данных. Для эффективной работы LLM в узкоспециализированной области оценки требуется ее настройка посредством промпта или файнтюнинга, формирование набора данных и специальных утилит.

Требуемые данные для разработки ассистента следующие:

- 1) макроэкономические, рыночные, финансовая отчетность компаний – для обучения и валидации стоимостных моделей в рамках трех подходов;
- 2) корпус отчетов об оценке – коллекция завершенных отчетов, прошедших аудит, с обезличенными данными, что является основным материалом для обучения модели правильной структуре, стилистике и терминологии;
- 3) нормативные документы – федеральные стандарты оценки (ФСО), методические рекомендации, законодательные акты;
- 4) учебные материалы и статьи – профессиональная литература по методологии стоимостной оценки активов и бизнеса;
- 5) диалоговые пары – специально сгенерированные примеры диалогов между экспертом и ассистентом («Найди аналоги для компании XXX в нефтегазовой отрасли», «Сгенерируй описание объекта на основе его технического паспорта», «Объясни разницу между рыночной и ликвидационной стоимостью»).

На основе этих данных создается итоговый набор для тонкой настройки модели в формате «запрос-ответ» (instruction-response) или построения системы на основе RAG (Retrieval-Augmented Generation) технологии.

Описание основного функционала. Ассистент, построенный на генеративном ИИ, должен реализовать следующий функционал (в данном случае каждый функционал может быть реализован отдельным агентом):

- 1) интеллектуальный поиск по внешним источникам информации, необходимой для корректной идентификации факторов стоимости;
- 2) расчеты в рамках подходов и методов стоимостной оценки бизнеса;
- 3) генерация разделов отчета об оценке – ассистент способен по наброску или структурированным данным создавать текстовые разделы в соответствии с требованиями ФСО, избегая субъективных и неаргументированных утверждений;

4) ответы на вопросы и экспертная поддержка – система работает как чат-бот, консультируя оценщика по методологии, что снижает когнитивную нагрузку на специалиста и ускоряет процесс принятия решений;

5) контроль качества и согласованность результатов – модель может использоваться для проверки готовых отчетов на наличие внутренних противоречий, соответствия стандартам и используемых формулировок и расчетов;

6) прочие операции (в силу ограниченного объема статьи не представлены).

Проектирование архитектуры. Архитектура ассистента может быть спроектирована как модульная система с микросервисной организацией.

Далее рассмотрен пример архитектуры агента для поиска новостных сообщений по оцениваемой компании. Ядром системы является крупная языковая модель Giga-chat-2-max или pro [9]. Giga-chat-2-max/pro выбрана как современная отечественная LLM, демонстрирующая высокие результаты в задачах понимания и генерации текста на русском языке. Также важно отметить ее способность работать с длинным контекстом (большим размером окна), позволяет анализировать большие объемы данных.

Архитектура системы включает следующие компоненты.

1. Библиотеки: langchain-gigachat (интеграция GigaChat с LangChain, используется для построения цепочек запросов к LLM); langgraph (библиотека для создания графовых структур агентов и цепочек LangChain); langchain-community (расширения и коннекторы от сообщества для LangChain); langchain (основной фреймворк для работы с LLM, агентами, памятью и пайплайнами).

2. Основной инструмент, который может использоваться агентом для поиска в сети – DuckDuckGo.

3. Системный промпт для действий агента: «template="""

Ты финансовый аналитик. Тебе нужно проанализировать новости, определить дату, источник новости и оценить ее влияние на компанию.

Раздели новости по отдельности и оцени каждую. Верни результат строго в формате JSON-массива, где каждая новость – объект.

```
[{"Company": "Название компании",  
  "News Summary": "Краткое содержание одной новости",  
  "Impact Assessment": "Положительное / Отрицательное / Нейтральное +  
  пояснение",  
  "News source": "Источник новости",  
  "Date": "Дата"  
}]  
Company: {company}  
News: {news}  
""";
```

4. Инициализированный агент: agent = initialize_agent(tools=tools, llm=model, agent=AgentType.ZERO_SHOT_REACT_DESCRIPTION, verbose=True). В данных параметрах компонуются набор инструментов (tools), параметры llm-модели (model="GigaChat-Pro" по api), тип агента (Zero-shot – работает без примеров, ReAct-архитектура (Reasoning (рассуждение) + Acting (действие))).

5. Результаты могут быть предоставлены в формате списка в Excel или выведены на поверхность используемого интерфейса (например, с использованием gradio).

Заключение. В работе представлена концепция ассистента оценщика, основанного на возможностях генеративного ИИ. В качестве технологической основы предложено использование языковой модели Giga-chat, интегрированной в модульную архитектуру с применением фреймворка GigaChain для оркестрации рабочего пространства. Представлен пример архитектуры агента по поиску новостных сообщений по компании.

Ключевыми преимуществами внедрения такого ассистента являются:

- сокращение временных затрат на рутинные операции по поиску и анализу информации;
- повышение качества отчетов за счет автоматической проверки на соответствие стандартам;
- снижение когнитивной нагрузки на эксперта и минимизация ошибок из-за человеческого фактора;
- ускорение обучения новых специалистов за счет встроенной экспертной поддержки.

Дальнейшие исследования направлены на детальную проработку функционала других агентов. Важной задачей является также обеспечение безопасности и конфиденциальности обрабатываемых данных.

Библиографический список

1. Profet.ai: Real Estate Valuation & Property Analytics Solutions. URL: <https://appraisalbuzz.com/propmix-unveils-appraisal-assistant-the-ai-agent-poised-to-revolutionize-real-estate-appraisals/#:~:text=Appraisal%20Assistant%20is%20built%20on,enabling%20faster%2C%20more%20accurate%20appraisals> (дата обращения: 21.09.2025).
2. HouseCanary: Smarter real estate decisions start with instant insights. URL: <https://www.housecanary.com/products/canary-ai/#:~:text=Introducing%20the%20first,leading%20analytics> (дата обращения: 21.09.2025).
3. HouseStack: Real estate intelligence platform. URL: <https://housestack.ai/#:~:text=Appraisal%20Pro%20AI,process%20and%20appraisal%20report%20generation> (дата обращения: 21.09.2025).
4. AutoMax – Alif. URL: <https://www.automax.ai/#:~:text=Search%20for%20Comparables> (дата обращения: 21.09.2025).
5. SRG-IT: Технологии для оценки недвижимости – SRG-IT. URL: <https://srg-it.tech/oczenka> (дата обращения: 21.09.2025).
6. Cyndx: Product Valer – AI Valuation Tool. URL: <https://cyndx.com/product-valer> (дата обращения: 21.09.2025).
7. FinGPT: AI Chatbot for Financial Services. URL: <https://chat.finuslugi.ru/fingpt2> (дата обращения: 21.09.2025).
8. Федеральный стандарт оценки «Оценка бизнеса (ФСО № 8)» (утв. приказом Минэкономразвития России от 01.06.2015 № 326). URL: <https://www.stocf.ru/o-kompanii1/sootvetstvie-fso/62-fso-8-otsenka-biznesa> (дата обращения: 21.09.2025).
9. GigaChat API: документы. URL: <https://developers.sber.ru/docs/ru/gigachat/overview> (дата обращения: 01.10.2023).

THE CONCEPT OF AN ASSISTANT APPRAISER BASED ON GENERATIVE ARTIFICIAL INTELLIGENCE TECHNOLOGY

Pomulev Alexander Alexandrovich

Financial University under the Government of the Russian Federation
125167, Russia, Moscow, Leningradsky Ave, 49/2
me@pomulev.ru

The article discusses the concept of developing a software assistant for appraisers based on the capabilities of generative artificial intelligence (hereinafter Gen AI). The relevance of the work is due to the need to process large volumes of structured and unstructured data, as well as to minimize the subjective factor in the appraisal process. The use of the large language model (LLM) GigaChat (Giga-chat-2-max) as the core of the system is proposed. The article describes the task setting, the formation of a dataset for training and configuring the model, the key functionality of the assistant, and the design of its architecture.

Keywords: generative artificial intelligence, large language model, assessment of valuation, assessment activity, assistant for appraisers

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ СТОИМОСТИ ПЕРВИЧНОГО РЫНКА КВАРТИР В ГОРОДЕ ПЕРМИ

Попов Данил Андреевич

Пермский государственный национальный исследовательский университет, ФИТ
614990, Россия, г. Пермь, ул. Букирева, 15
borovkun@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования стоимости квартир в городе Перми. Система позволяет с большой точностью предсказать стоимость квартиры на основании данных домов, в которых они расположены, отделки самих квартир и мировой экономики.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, оценка стоимости, первичный рынок квартир

Введение. Данная работа не является первой по своей тематике, присутствуют и другие ранее разработанные системы, но у них есть два больших отличия: спустя время данные о рынке недвижимости становились неактуальными, и оценка стоимости велась вторичного рынка квартир, а не первичного. Оценка стоимости недвижимости – процесс не из легких из-за большого количества факторов влияния на итоговую стоимость, таких как площадь, этаж, количество этажей в доме, тип планировки, тип отделки, материал стен дома, расстояние дома до центра и т.д. Как показал опыт Пермской научной школы искусственного интеллекта, например [1–3], правильно натренированная нейросетевая система может добиться успешности большей части прогнозов.

Также при анализе этих источников по оценке стоимости недвижимости выяснилось, что все работы направлены на оценку стоимости вторичного рынка квартир. В данной работе задействованы данные первичного рынка квартир для анализа их стоимости, так как у квартир первичного рынка также есть ряд параметров, влияющих на стоимость. Также в некоторых из прошлых работ была указана проблема актуальности во времени [4–6], что подразумевает актуальность цен квартир на определенный промежуток времени, которая зависит от различных макроэкономических параметров, например курса доллара, цены нефти и т.д. Так как в данной работе рассматривается первичный рынок, данные параметры автором не учитываются, ибо не рассматривается исторический фактор стоимости. В работе [6] была разработана тепловая карта для определения локальных ценовых центров городов, это было сделано с целью определения максимальной стоимости квартир, а также взяты макроэкономические параметры. Отличием авторской работы от [6] является то, что автор не разрабатывал тепловые карты, а рассчитал расстояние дома до центра Перми, используя координаты, и не использовал макроэкономические параметры.

Изучая подобные работы, автором не было найдено работ, оценивающих стоимость именно первичного рынка квартир.

Большинство параметров является общедоступной информацией, например площадь или этаж квартиры. Но есть и параметры, которые не каждый застройщик выставит в свободный доступ, например тип стен дома или особенность планировки. Также в работе присутствуют дополнительные параметры, которые нельзя оставлять без внимания, ибо с каждым годом квартир с «нетиповой» отделкой и местоположением становится все больше и больше.

Основная цель настоящей работы заключается в сборе множества данных квартир, строящихся или уже построенных в городе Перми, а также создание и обучение нейросетевой модели на этих данных. Конечным результатом должна стать нейросетевая система, способная прогнозировать стоимость как типовых, так и нетиповых квартир первичного рынка.

Для создания нейросетевой системы выбраны следующие параметры: X1 – общая площадь, X2 – количество комнат, X3 – этаж, X4 – количество этажей в доме, X5 – год постройки, X6 – тип отделки, X7 – ввод жилья в эксплуатацию, X8 – тип стен дома, X9 – расстояние до центра города, X10 – особенность планировки. Выходным параметром является D1 – стоимость квартиры (в рублях).

Обучающее множество было собрано вручную. Перед переходом к проектированию и обучению нейросетевой модели выполнена очистка исходного множества от противоречивых примеров и дубликатов. Так, противоречивыми примерами считались те, где маленькая квартира без особой планировки не в центре города стоила очень дорого. Таким образом, объем итогового множества включает в себя 128 примеров. Данное множество было разделено на обучающее и тестирующее: 80 и 20% соответственно. Большая часть данных собрана с интернет-ресурсов.

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 десять входных нейронов, один выходной и один скрытый слой с тремя нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 26 примеров. Средняя относительная ошибка тестирования составила 1,5%, что можно считать отличным результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью значением стоимости квартир.




Рис. 1. Результат тестирования нейронной сети

Из результатов, изображенных на рис. 1, можно сделать вывод об адекватной работе спроектированной нейронной сети.

На рис. 2 видно, что наиболее значимыми являются особенность планировки квартиры, общая площадь квартиры, тип стен дома, количество этажей в доме, ввод жилья в эксплуатацию и тип отделки. Как и ожидалось, наиболее влиятельным параметром является особенность планировки. От особенности планировки, будь то: 3 спальни, наличие лоджии, наличие 2 или 3 уровня – зависит и общая стоимость квартиры.




Рис. 2. Значимость входных параметров нейросетевой модели

Далее проведено исследование полученных зависимостей между входными параметрами и стоимостью квартир. Исследование производилось с помощью метода «замораживания», суть которого заключается в варьировании значения одного параметра и фиксировании значений всех других параметров. Для этой цели было выбрано 5 квартир, про которые нейросеть не может с уверенностью сказать, у какой квартиры какая стоимость.

1. Однокомнатная квартира площадью 36 кв. м на 15-м этаже 16-этажного панельного дома, введенного в эксплуатацию.

2. Двухкомнатная квартира площадью 58,42 кв. м на 16-м этаже 19-этажного кирпичного дома, не введенного в эксплуатацию.

3. Трехкомнатная квартира площадью 86,87 кв. м на 2-м этаже 17-этажного панельного дома, не введенного в эксплуатацию.

4. Четырехкомнатная квартира площадью 84,8 кв. м на 16-м этаже 22-этажного панельного дома, не введенного в эксплуатацию.

На рис. 3 показан график зависимости стоимости квартир от особенности отделки. В том случае, когда у квартиры появляется особенность в планировке, нейросеть прогнозирует значительное увеличение стоимости.




Рис. 3. Зависимость стоимости квартиры от особенности планировки

На рис. 4 продемонстрирована зависимость стоимости квартир от прогноза общей площади квартиры. Можно заметить, что увеличение площади квартиры ведет к росту ее стоимости.




Рис. 4. Зависимость стоимости квартиры от общей площади

На рис. 5 изображен график зависимости стоимости от количества этажей в доме. Как видно из графика, тенденция снижения стоимости в зависимости от увеличения количества этажей в доме распространяется до определенного количества этажей, после же цена начинает подниматься.

На рис. 6 изображен график зависимости стоимости квартиры от факта введения жилья в эксплуатацию. Как видно из графика, при введении жилья в эксплуатацию стоимость квартиры поднимается.

На рис. 7 изображен график зависимости стоимости квартиры от расстояния до центра Перми. Как видно из графика, при увеличении расстояния до центра Перми цена снижается, кроме 1-комнатной квартиры, которая, в свою очередь, является еще и самой дальней по расположению.




Рис. 5. Зависимость стоимости квартиры от количества этажей в доме




Рис. 6. Зависимость стоимости квартиры от факта введения квартиры в эксплуатацию




Рис. 7. Зависимость стоимости квартиры от расстояния до центра Перми

Полученные результаты исследований не противоречат реальности, что подтверждает то, что спроектированную нейронную сеть можно считать пригодной для прогнозирования результатов стоимости первичного рынка квартир.

Заключение. Построена система нейросетевого прогнозирования оценки стоимости первичного рынка квартир города Перми. Спроектированная нейросетевая модель учитывает 10 параметров: общую площадь, количество комнат, этаж, количество этажей в доме, год постройки, тип отделки, ввод жилья в эксплуатацию, тип стен дома, расстояние до центра Перми, особенность планировки. Методом сценарного прогнозирования построены графики зависимостей прогнозируемой стоимости квартир от изменения входных параметров. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать стоимость квартир. Данный набор параметров может быть изменен для прогнозирования стоимости первичного рынка квартир другого города.

Библиографический список

1. Ясницкий Л. Н., Ясницкий В. Л. Методика создания комплексной экономико-математической модели массовой оценки стоимости объектов недвижимости на примере квартирного рынка города Перми // Вестник Пермского университета. Серия: Экономика. 2016. № 2 (29). С. 54–69.
2. Ясницкий Л. Н., Ясницкий В. Л. Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости жилых объектов на примере рынков недвижимости Екатеринбурга и Перми // Имущественные отношения в Российской Федерации. 2017. № 3 (186). С. 84.
3. Yasnitsky L. N., Yasnitsky V. L., Alekseev A. O. The complex neural network model for mass appraisal and scenario forecasting of the urban real estate market value that adapts itself to space and time // Complexity. 2021. Article 5392170. DOI [10.1155/2021/5392170](https://doi.org/10.1155/2021/5392170)
4. Becker C., Morrison A.R. Urbanization in transforming economies // Handbook of Regional and Urban Economics. 1999. Vol. 3. P. 1673–1790.
5. Кукарин И. А., Сухов А. О. Применение нейронных сетей для оценки стоимости квартир на примере рынка недвижимости Перми // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всерос. науч.-практ. конф. (г. Пермь, 21–24 мая 2019 г.) Ч. I. Пермь, 2019. С. 112–116.
6. Гилязов И. Г., Алексеев А. О., Ясницкий В. Л. Самоадаптируемая нейросетевая система оценки и прогнозирования рынков недвижимости Нижнего Новгорода и Перми // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всерос. науч.-практ. конф. (г. Пермь, 21–24 мая 2019 г.) Ч. I. Пермь, 2019. С. 93–101.
7. Черепанов Ф. М., Ясницкий Л. Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RU 2014612546. Заявка № 2014610341 от 15.01.2014.
8. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Академия, 2005. 176 с.

NEURAL NETWORK SYSTEM FOR PREDICTING THE COST OF THE PRIMARY APARTMENT MARKET IN THE CITY OF PERM

Popov Danil Andreevich

Perm State University
15, Bukireva Str., Perm, Russia, 614068
borovkun@gmail.com

The article describes the development of a neural network system for predicting the cost of apartments in the city of Perm. The system allows you to predict the cost of an apartment with great accuracy based on the data of the houses in which they are located, the decoration of the apartments themselves and the world economy.

Keywords: artificial intelligence, neural network technologies, forecasting, valuation, primary apartment market

НЕЙРОСЕТЕВАЯ СИСТЕМА ДЛЯ ПРОГНОЗИРОВАНИЯ ЦЕН ЖИЛОЙ НЕДВИЖИМОСТИ В МОСКВЕ

Черемных Александр Александрович

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
cherema049@yandex.ru

В статье описана разработка нейросетевой системы для прогнозирования цены недвижимости в Москве. Модель создавалась с использованием «Нейросимулятора» и Python с библиотекой Keras, при этом лучшее качество показал «Нейросимулятор». С помощью полученной модели проведено точное прогнозирование цен на основе характеристик квартир. Исследование выявило практические закономерности, а также определило ценность работы и перспективы дальнейшего изучения.

Ключевые слова: искусственный интеллект, нейросетевые технологии, цены на жилье, Москва

Введение. Прогнозирование стоимости недвижимости является важной и актуальной задачей. Это значимо как для государственных структур, так и для обычных граждан, риелторов. Предсказания о стоимости недвижимости помогают экономить при покупке или увеличить прибыль при продаже. Например, для государства прогнозирование недвижимости является ключевым элементом управления, влияющим на повышение эффективности государства, возможность инвестирования в строительство жилья.

Главным показателем рынка недвижимости, отражающим реальную ситуацию, является ее цена, поскольку она наиболее чувствительно реагирует на изменения. Поэтому ключевым аспектом прогнозирования в сфере недвижимости является ценообразование. Стоимость недвижимости зависит от различных факторов, а именно качественных характеристик объекта.

Обзор литературы. В России с 1990-х гг. значительное внимание уделяется исследованиям оценки стоимости недвижимости. Серия научных работ, начиная с исследований С. В. Грибковского, Г. М. Стерника и Д. Б. Житкова, посвящена развитию экономико-математических методов оценки [1].

Исследуются различные модификации методов и создаются модели на данных городов Москвы и Санкт-Петербурга. Видный вклад в данную область внес Г. М. Стерник, изучивший ценообразование на рынке жилья в России, выделивший ценообразующие факторы и классифицировавший их по уровням относительно спроса и предложения. Подобная классификация широко используется в исследованиях недвижимости и служит основой для дальнейших исследований [2].

А. В. Печенкина использовала в своем исследовании многоуровневую факторную модель для прогнозирования рынка недвижимости в городе Перми [3]. М. Ю. Молчанова применила сценарный метод прогнозирования ситуации на рынке недвижимости, представив несколько сценариев событий [4].

Работа Р. Р. Хабабрахмановой посвящена моделированию динамики цен на рынке жилья в городе Казани с использованием модели Фишера Прая [5]. В области оценки недвижимости начали применяться нейронные сети для обучения без привязки к географическому местоположению, например модель, разработанная Л. Н. Ясницким [6].

В зарубежной литературе имеются исследования, посвященные разработке и использованию альтернативных моделей массовой оценки недвижимости на основе нейронных сетей. Проблемы применения нейросетевых методов в системах оценки недвижимости были изучены в работах многочисленных авторов, в основном иностранных. Результаты демонстрируют, что для оценки стоимости недвижимости более эффективным является использование нейронных сетей, чем традиционных многомерных регрессионных моделей [7].

Актуальность. Прогнозирование цен на рынке недвижимости постоянно развивается, и каждый год появляется все больше работ в этой области. Данное исследование поможет составить представление о том, что будет с рынком недвижимости в будущем, тем самым позволяя определить, верно ли принято инвестиционное решение и будет ли оно эффективным.

Постановка задачи. Цель исследования заключается в сборе данных по объектам недвижимости Москвы, обучении нейросетевой модели с разными инструментами для выбора оптимальной, а затем анализе ее закономерности. В итоге предполагается создать систему, точно прогнозирующую цены квартир.

Формирование DataSet. Для создания работы выбран набор показателей: X_1 – общая площадь (m^2), X_2 – жилая площадь (m^2), X_3 – площадь кухни (m^2), X_4 – расстояние от центра (км), X_5 – расстояние до ближайшей станции метро (мин), X_6 – возможность добраться до ближайшей станции метро пешком, X_7 – тип дома, X_8 – этаж, X_9 – район. Выходной параметр D_1 – цена квартиры (в тыс. \$).

Часть параметров закодирована по различным принципам. Район принимает значения: 1 – Север, метро Калужско-Рижская линия, 2 – Север, метро Серпуховско-Тимирязевская линия, 3 – Северо-Запад, метро Замоскворецкая линия, 4 – Северо-Запад, метро Таганско-Краснопресненская линия, 5 – Юго-Восток, метро Люблинская линия, 6 – Юго-Восток, метро Таганско-Краснопресненская линия, 7 – Восток, метро Калининская линия, 8 – Восток, метро Арбатско-Покровская линия.

Единица означала пешую доступность метро и расположение квартиры не на первом или последнем этаже; в остальных случаях ноль. Также кирпичный или монолитный дом обозначался единицей, иначе нулем.

Для обучения нейросети использованы данные с сайта Kaggle [8]. Множество очищено от противоречий, выбросов и дубликатов с помощью функций «Нейросимулятора 5» [10] и Python. В итоге собрано 4100 примеров, которые перемешали и разделили на обучающее (80%) и валидационное (20%) множества, при этом обучающее далее было разделено на обучающее (90%) и тестовое (10%).

Проектирование, обучение и тестирование нейросети. Проектирование, обучение и тестирование нейросети проводились в «Нейросимуляторе 5» по методике из [11]. В итоге создан персептрон с 9 входами, 1 выходом и 3 скрытыми слоями по одному нейрону в каждом. Активация вводного и скрытых слоев – гиперболический тангенс, выходного – линейная функция.

Обучение сети проводилось на 1329 примерах обучающего и 280 валидационного множеств. Для тестирования использовались 190 примеров. Средняя ошибка составила 8,76%, что считается удовлетворительным. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью значением цен на квартиры.




Рис. 1. Результат тестирования нейронной сети в Нейросимулятор 5

Из результатов, изображенных на рис. 1, сделан вывод о достаточно адекватной работе спроектированной нейронной сети в программе.

Работа нейросети в Python с Keras сравнивалась с [10] для оценки их эффективности и выбора оптимального инструмента. В итоге создана сеть с тем же числом входных и выходных параметров. В качестве экспериментов применено несколько функций активации для оценки качества обучения нейросети.

Определено, что модель, использующая функцию активации ReLU, продемонстрировала лучший результат в сравнении с моделью, использующей функцию активации Tanh. Значения их коэффициентов детерминации (далее R^2) составили соответственно 0,67 и 0,59.

Для сравнения точности прогнозов первой и второй моделей сопоставлены графики по сравнению фактических и прогнозируемых результатов. На рис. 2 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью значением цен на квартиры, созданная на Python на небольшой выборке данных.




Рис. 2. Результат тестирования нейронной сети на Python

Из результатов сделан вывод о достаточно адекватной работе спроектированной нейронной сети с помощью Python и библиотеки Keras. Однако для полной проверки моделей вычислены и сравнены метрики для определения качества

обоих. R^2 для инструмента «Нейросимулятор 5.0» достиг значения 0,68, тогда как для Python (Keras) этот показатель составил 0,67. Делаем вывод, что сеть, построенная с помощью Нейросимулятора, продемонстрировала наилучший результат, в отличие от нейронной сети, разработанной с помощью Keras на языке программирования Python.

Таким образом, [10] может использовать лучшие алгоритмы оптимизации и обеспечивать более быструю скорость обучения, что помогло достичь лучших результатов. В рамках исследования прогнозирование цены за квартиру в Москве было продолжено с использованием первой модели.

Исследование предметной области. Оценка значимости входных параметров выполнена с помощью [10], результат отражен на рис. 3.




Рис. 3. Значимость входных параметров нейросетевой модели

Согласно рис. 3, наиболее значимыми параметрами, определяющими стоимость квартиры в Москве, являются площадь кухни, район и расстояние до центра. Факторы в совокупности оказывают наибольшее влияние на цену по причине их значимости для потенциальных покупателей и важности для обеспечения комфортной жизни в городе. Например, площадь кухни влияет на комфорт, а популярность района с развитой инфраструктурой повышает стоимость квартиры. Близость к центру города также влияет на цену из-за удобства доступа к важным объектам.

Проведен анализ влияния входных факторов на стоимость недвижимости с помощью метода «замораживания», при котором изменяется один параметр, удерживая остальные неизменными. Это позволяет определить вклад каждого фактора в итоговый результат. Рассмотрено влияние наиболее и относительно значимых параметров на прогнозируемый показатель цены. На рис. 4 показан график зависимости стоимости квартиры от самого значимого параметра – площади кухни (X_3).




Рис. 4. Зависимость цены квартиры от ее площади кухни

Из диаграммы видно, что между данными параметрами имеется взаимосвязь. Следовательно, можно заключить, что нейронная сеть прогнозирует увеличение стоимости квартиры пропорционально увеличению площади кухни. Вторым значимым параметром – район Москвы (X9).

На рис. 5 показано влияние местоположения квартиры на ее стоимость. Нейросеть определила, что северный район, обслуживаемый метро Калужско-Рижской линии, является самым дорогостоящим. На втором и третьем местах – районы севера с метро Серпуховско-Тимирязевской линии и северо-запада с метро Замоскворецкой линии.




Рис. 5. Зависимость цены квартиры от района

Самая низкая цена характерна для квартир на юго-востоке Москвы, вдоль линии метро Таганско-Краснопресненской линии. Важным фактором является также расстояние до центра (X4) от 0 до 26 км: модель показала, что чем ближе к центру, тем выше стоимость квартир. Данные представлены на рис. 6.




Рис. 6. Зависимость стоимости квартиры от расстояния до центра

Исходя из данных, представленных на рис. 6, можно сделать вывод, что при отметке показателя расстояния в пределах от 0 до 10 км цена квартиры варьируется в пределах 100 тыс. \$. При преодолении этого порога цена резко начинает снижаться.

Заключение. В результате исследования разработан математический аппарат искусственных нейронных сетей для прогнозирования цены за недвижимость в городе Москве. На этапе обзора литературы установлено, что нейросетевые модели оценки и прогнозирования рыночной стоимости квартиры точнее традиционных регрессионных моделей. Проведен эксперимент, в ходе которого создавались модели нейронной сети с применением Нейросимулятора и языка программирования Python с библиотекой Keras. Качество обеих моделей оценено, и лучший результат достигнут при использовании «Нейросимулятор 5.0».

Спроектированная нейросетевая модель успешно применена для прогнозирования конечного показателя с высокой точностью на основе данных о характеристиках квартиры. Она учитывает 9 входных параметров. При помощи сце-

нарного прогнозирования построены графики зависимости цены квартиры от ключевых факторов: площади кухни, расстояния до центра и района города. Другие параметры влияют значительно меньше.

Использование этих факторов в нейросетевой модели обеспечивает точное прогнозирование стоимости новостроек и недавно сданных домов, а также подходит для вторичного рынка. Добавление социоэкономических данных может повысить точность. Система показала корректную работу и пригодна для оценки рынка, планирования инвестиций и принятия решений о покупке или продаже.

Библиографический список

1. Грибовский С. В., Сивец С. А. Математические методы оценки стоимости недвижимого имущества: учеб. пособие для студ., обучающихся по спец. «Финансы и кредит». М.: Финансы и статистика, 2008. 366 с.
2. Грибовский С. В., Федотова М. А., Стерник Г. М., Житков Д. Б. Экономико-математические методы оценки недвижимости // Финансы и кредит. 2005. № 3 (171). С. 24–43.
3. Печенкина А. В. Использование многоуровневой факторной модели при прогнозировании ситуации на региональном рынке недвижимости (на примере Пермского края) // Имущественные отношения в РФ. 2010. № 11. С. 59–74.
4. Молчанова М. Ю. Применение сценарного метода при прогнозировании ситуации на рынке жилья г. Перми // Вестник Пермского университета. Серия: Экономика. 2015. № 1 (24). С. 79–88.
5. Хабибрахманова Р. Р. Моделирование динамики изменения цен на рынке жилья в г. Казани // Управление экономическими системами. 2015. URL: <https://cyberleninka.ru/article/n/modelirovanie-dinamiki-izmeneniya-tsen-na-rynke-zhilya-g-kazani>
6. Ясницкий Л. Н., Ясницкий В. Л. Методика создания комплексной экономико-математической модели массовой оценки стоимости объектов недвижимости на примере квартирного рынка города Перми // Вестник Пермского университета. Серия: Экономика. 2016. № 2 (29). С. 54–69.
7. Yasnitsky L. N., Yasnitsky V. L., Alekseev A. O. The complex neural network model for mass appraisal and scenario forecasting of the urban real estate market value that adapts itself to space and time // Complexity. 2021. Article 5392170. DOI [10.1155/2021/5392170](https://doi.org/10.1155/2021/5392170)
8. Price of flats in Moscow. URL: <https://www.kaggle.com/datasets/hugoncosta/price-of-flats-in-moscow/data>
9. Нейросимулятор 5.0: Свидетельство Роспатента о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. / Ф. М. Черепанов, Л. Н. Ясницкий.
10. Черепанов Ф. М., Ясницкий Л. Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Математика. Механика. Информатика. 2008. Вып. 4 (20). С. 151–155.
11. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Академия, 2005. 176 с.

NEURAL SYSTEM FOR PREDICTING RESIDENTIAL REAL ESTATE PRICES IN MOSCOW

Cheremnykh Aleksandr Aleksandrovich

HSE University

38, Studencheskaya Str., Perm, Russia, 614070

cherema049@yandex.ru

The article outlines the development of a neural network system for predicting real estate prices in Moscow. The model was created using both the Russian Neurosimulator and Python with Keras, with the Neurosimulator yielding the best results. This model enabled accurate price forecasting based on apartment data. The intelligent system also helped identify practically significant patterns, highlighting the work's value and future research prospects.

Keywords: artificial intelligence, neural network technologies, housing prices, Moscow

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ОЦЕНКИ КАЧЕСТВА МОЛОКА

Цидвинцев Захар Викторович

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, д. 38
zakhar.tsidvintsev@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования оценки качества молока по его вкусо-видовым характеристикам. С помощью разработанной интеллектуальной системы проведено исследование предметной области, выявлены закономерности, имеющие практическое значение.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, молочные продукты

Введение. По данным Федеральной службы государственной статистики [1], среднестатистический житель Российской Федерации потребляет около 240 кг молока и молочных продуктов в год (в 2020–2022 гг.). Это почти в 4 раза больше количества потребляемого картофеля, в 4 раза – мяса, в 2,5 раза – овощей. Больше россияне потребляют только яиц – около 280 кг в год на душу населения. Такой высокий объем потребления связан с тем, что для производства некоторых молочных продуктов требуется большой объем сырья. Например, для производства 1 кг сыра может потребоваться от 10 до 12 кг молока [2].

Молоко и молочные продукты составляют большую часть рациона потребителя. Именно поэтому важно иметь способ прогнозирования оценки молока потребителем исходя из его вкусовых и видовых характеристик.

Анализ литературы показал, что основным заинтересованным лицом в применении нейросетевых моделей и методов машинного обучения для определения качества молочной продукции является производитель этой самой продукции [3–4]. При этом в основном оценка качества производится по химическим параметрам продукции, а не по ее вкусо-видовым характеристикам. Но потребитель молока обычно не имеет доступа к технологиям определения химического состава. Поэтому необходимо определить ключевые параметры внешнего вида и вкуса, которые сильнее всего влияют на оценку качества молока.

Целью данной работы является определение ключевых вкусо-видовых характеристик, влияющих на оценку качества молока, с помощью нейросетевой модели, умеющей прогнозировать оценку.

Постановка задачи. Для создания модели предсказания оценки качества молока были выбраны следующие характеристики.

1. Кислотность (значение pH) – X1, pH.
2. Температура (в градусах Цельсия) – X2, Temperature.
3. Вкус (0 – плохой, 1 – хороший) – X3, Taste.

4. Запах (0 – плохой, 1 – хороший) – X4, Odor.
5. Жирность (0 – нежирное, 1 – жирное) – X5, Fat.
6. Мутность (0 – немутное, 1 – мутное) – X6, Turbidity.
7. Цвет (RGB от 240 до 255) – X7, Color.

Результирующий признак (Оценка качества) закодирован символом Y.

Данные были взяты с интернет-ресурса Kaggle [5]. Результирующий признак в множестве был категориальным, имел три возможных значения: Low, Medium и High. Категориальные значения были заменены на числовые –1, 0 и 1 соответственно. Объем множества составляет 1059 примеров. Данное множество было разделено на обучающее, валидирующее и тестирующее в соотношении 80:14:6 соответственно.

Проектирование нейронной сети. Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [6] по методике [7].

В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет семь входных нейронов, один выходной и один скрытый слой с тремя нейронами. Активационная функция входного нейрона – сигмоида, у всех остальных – гиперболический тангенс. Средняя относительная ошибка тестирования составила 7,7%, что можно считать приемлемым результатом.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 20 примеров. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактической и прогнозируемой нейросетью оценкой качества молока.




Рис. 1. Доказательство адекватности работы модели

Из результатов, изображенных на рис. 1, можно сделать вывод об адекватной работе спроектированной нейронной сети.

Кроме того, для оценки качества полученной модели был вычислен коэффициент детерминации (r^2). Результат составил 0,992, что также говорит о высоком качестве полученной модели.

Далее было выполнено проектирование и тестирование с помощью библиотеки Keras [8] для создания нейронных сетей, написанной на языке Python. С помощью Keras можно настроить большее количество гиперпараметров нейрон-

ной сети, чем с помощью Нейросимулятора. Однако настраивать нейросеть графически, как в Нейросимуляторе, нельзя, что увеличивает сложность проектирования сети.

В итоге проектирования была получена структура нейронной сети, состоящая из 7 входных нейронов с активационной функцией “ReLu”, одного выходного и трех нейронов на скрытом слое с активационными функциями – гиперболический тангенс.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 20 примеров. На рис. 2 представлена гистограмма, демонстрирующая разницу между фактической и прогнозируемой нейросетью оценкой качества молока.




Рис. 2. Доказательство адекватности модели, созданной с помощью Keras

Кроме того, для оценки качества полученной модели был вычислен коэффициент детерминации (r^2). Результат составил 0,986, что так же говорит о высоком качестве полученной модели.

Исследование предметной области. Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор», результат отображен на рис. 3.




Рис. 3. Значимость входных параметров нейросетевой модели

Таким образом, можно сделать вывод, что больше всего на ощущение пользователя от молока влияют его кислотность и температура.

Далее было проведено исследование наиболее значимых полученных зависимостей между входными параметрами и оценкой качества молока.

На рис. 4 изображен график зависимости оценки качества молока от его температуры. Молоко, температура которого близка к температуре тела человека, ощущалось пользователями вкуснее, чем более горячее.




Рис. 4. Зависимость оценки качества молока от температуры

На рис. 5 изображен график зависимости оценки качества молока от его показателя кислотности.




Рис. 5. Зависимость оценки качества молока от кислотности

Как видно из графика на рис. 5, высокие оценки получило молоко со значением pH около 6,5–7. Такие значения являются нормальной кислотностью для свежего молока [9].

Заключение. Построена нейросетевая модель прогнозирования оценки качества молока на основе его вкусо-видовых характеристик. С помощью модели получены данные о значимости параметров. Можно сделать вывод, что температура и кислотность молока являются определяющими для потребителя в вопросе оценки качества молока. Следующий этап в развитии определения предпочтений пользователя может стать анализ оценки вкуса молока на основе маркетинговых показателей, например узнаваемости и позиционирования бренда.

Библиографический список

1. Потребление основных продуктов питания населением Российской Федерации // Федеральная служба государственной статистики. 2023. URL: <https://rosstat.gov.ru/compendium/document/13278>
2. Завьялова Н. Откуда в России столько молока? // РОСКАЧЕСТВО. 31.05.2021. URL: <https://rskrf.ru/tips/spetsproekty/skolko-v-rossii-moloka/>
3. Давыдова Г. Р., Потапов А. С. Контроль качества творога по органолептическим показателям с применением нейронных сетей // Молочная промышленность. 2012. № 9. С. 44–45.
4. Казанцев А. Н. Новые цифровые технологии в молочном животноводстве // Вавиловские чтения. 2022. С. 706–708.
5. Milk Quality Prediction // Kaggle. URL: <https://www.kaggle.com/datasets/cpluzshrijayan/milkquality>
6. Черепанов Ф. М., Ясницкий Л. Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
7. Ясницкий Л. Н. Интеллектуальные системы: учебник. М.: Лаборатория знаний, 2016. 221 с.
8. Keras 3 API documentation // Keras. URL: <https://keras.io/api>
9. Секреты сыроделия – кислотность молока и сыра // Ферма Вкуса. 2022. URL: <https://fermavkusa.ru/blogs/publikatsii/sekrety-syrodeliya-kislotnost-moloka-i-syra>

NEURAL NETWORK SYSTEM FOR PREDICTING MILK QUALITY ASSESSMENT

Zakhar V. Tsidvintsev

HSE University

38, Studencheskaya Str., Perm, Russia, 614990

zakhar.tsidvintsev@gmail.com

The paper describes the development of a neural network system for predicting the assessment of milk quality by its flavor and species characteristics. With the help of the developed intellectual system the research of the subject area is carried out, the regularities of practical importance are revealed.

Keywords: artificial intelligence, neural network technologies, forecasting, dairy products

НЕЙРОННАЯ СЕТЬ КАК ИНСТРУМЕНТ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПО ЛИКВИДАЦИИ ЭКОНОМИЧЕСКИХ ПОСЛЕДСТВИЙ НЕШТАТНЫХ СИТУАЦИЙ

Мезенцев Алексей Сергеевич

ООО "Интеллект Софт"

614095, Пермский край, г Пермь, ул Карпинского, д. 50

alexey537@yandex.ru

Ясницкий Виталий Леонидович

ООО "Интеллект Софт"

614095, Пермский край, г Пермь, ул Карпинского, д. 50

yasnitskiy@mail.ru

Миролюбова Татьяна Васильевна

Пермский государственный национальный исследовательский университет,

614990, Россия, г. Пермь, ул. Букирева, 15

mirolubov@list.ru

Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет,

614990, Россия, г. Пермь, ул. Букирева, 15

yasn@psu.ru

На примере серийного производства стальных отливок показана возможность применения нейронных сетей в качестве системы поддержки принятия решений по снижению отрицательных экономических последствий некоторых нештатных ситуаций, связанных со сбоями поставок сырьевого материала.

Ключевые слова: нештатная ситуация, производственный брак, нейронная сеть, прогнозирование, сырьевой материал, моделирование.

Введение. Возникновение нештатных ситуаций во время любого серийного производственного процесса, не является редкостью. Это может быть поломка и выход из строя какой-либо отдельной единицы оборудования в общей цепочке технологического процесса, изменение его рабочих характеристик, связанных с износом отдельных деталей, изменением химического состава и, соответственно, рабочих характеристик используемого сырьевого материала, аномальное изменение погодных условий, нарушение дисциплины труда производственного персонала и др. Возникновение таких нештатных ситуаций часто приводит к резкому возрастанию процента брака производимой продукции. Для устранения нештатных ситуаций, как правило, приходится временно останавливать весь производственный процесс, что, естественно, приводит к снижению общей экономической эффективности производства. В настоящей статье на примере серийного производства стальных отливок в мартеновской печи, мы показали, что в некоторых случаях можно уменьшить экономические потери пред-

приятия, связанные с нештатными ситуациями и ростом производственного брака, путем применения метода нейросетевого математического моделирования производственного процесса.

Математическая модель производственного процесса. В отличие от традиционно применяемых ранее детерминированных методов построения математических моделей производственных процессов [1, 2], в основу нашей модели легла нейронная сеть. Она имела полносвязную слоистую структуру типа многослойного персептрона с сигмоидными нейронами. Сеть обучалась на множестве данных, собранных в течение нескольких лет на одном из уральских металлургических предприятий. Входными переменными нейронной сети являлись параметры работы мартеновской печи (объем металла в ковше, основность шлака, продолжительность плавки, продолжительность кипения и др.), химический состав металла (C, Mn, P, S, Si, Cr, Ni, Cu, Al и др), а также параметры, оказывающие на производственный процесс косвенное влияние (день недели, время года, влажность и температура воздуха, ID сталевара и др).

Предобработка данных, проектирование, обучение, валидация и тестирование нейронной сети выполнялось с использованием программного инструмента «Нейросимулятор 5.0 [3], алгоритма поиска и исключения выбросов статистической информации [4], а также других приемов Пермской научной школы искусственного интеллекта www.PermAI.ru. Отметим, что попытки добиться сколько-нибудь приемлемых по точности альтернативных нейросетевых моделей с помощью современных фреймворков на базе существующих Python-библиотек, как видно из [5], к успеху не приводили.

Пример ликвидации последствий нештатных ситуаций. На заводе «А» случаются несвоевременные поставки ферросиликомарганца, выполняющего роль полезного легирующего элемента. Согласно данным нейросетевого моделирования, уменьшение этого входного параметра нейросетевой модели с регламентного значения 900 кг до нуля приводит к резкому возрастанию процента брака с 4,8% до 14,4%, что и наблюдается в действительности.

Однако вместо того, чтобы немедленно останавливать производственный процесс и ждать поставки новой партии ферросиликомарганца, мы предлагаем выполнить серию виртуальных компьютерных экспериментов – путем виртуального изменения входных параметров модели, пытаемся подобрать такие изменения состава расплава, чтобы рост процента брака был не таким значительным. Результаты таких виртуальных экспериментов показали, что снизить процент брака в сложившейся нештатной ситуации можно, например, путем увеличения ферросилиция с 400 кг до 1000 кг, и/или путем увеличения продолжительности чистого кипения расплава с 8,3 до 15 часов.

Как показали расчеты, такая временная работа мартеновской печи с измененными параметрами плавки, экономически более выгодна для предприятия, чем остановка производственного процесса и ожидание подвоза необходимых компонентов.

Заключение. Нейросетевые математические модели серийных производственных процессов можно использовать в качестве инструментов поддержки принятия решений для оперативной ликвидации последствий нештатных ситуа-

ций, связанных с падением экономической эффективности предприятий из-за сбоев поставки сырьевого материала, выходом из строя, либо некачественной работой отдельных единиц оборудования производственных линий.

Поддержка исследований. Работа выполнена при поддержке Фонда содействия развитию малых форм предприятий в научно-технической сфере (Россия), заявка № С1-231505: «Нейросетевая система прогнозирования брака литейных изделий и оптимального выбора параметров технологических процессов их производства».

Библиографический список

8. Самойлович Ю.А., Ясницкий Л.Н. Сопряженная задача теплообмена, гидродинамики и затвердевания расплава // Инженерно-физический журнал. 1981. Т. 41. № 6. С. 1109-1118.
9. Ясницкий Л.Н. Метод фиктивных канонических областей в механике сплошных сред. Москва, 1992.
10. Нейросимулятор 5.0 : Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ). <https://cloud.mail.ru/public/Jr29/RzgouF6b9>.
11. Yasnitsky L.N. Algorithm for searching and analyzing abnormal observations of statistical information based on the Arnold – Kolmogorov – Hecht-Nielsen theorem // International Journal of Advanced Trends in Computer Science and Engineering. 2020. 9(2). Pp. 1814-1819. DOI: 10.30534/ijatcse/2020/139922020 <http://www.warse.org/IJATCSE/static/pdf/file/ijatcse139922020.pdf>
12. Штейнле Д.К., Ясницкий Л.Н. Анализ данных и создание системы машинного обучения для оптимизации процесса выплавки высокопрочной стали // 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, 17–18 октября 2024 г.); Пермский государственный национальный исследовательский университет. – Пермь, 2024. – Ч. 1. – С.217–223

NEURAL NETWORK AS A DECISION SUPPORT TOOL FOR ELIMINATION OF ECONOMIC CONSEQUENCES OF EMERGENCY SITUATIONS

Aleksey Mezentsev

Intellect Soft LLC

50 Karpinsky Street, Perm, 614095, Perm Krai

alexey537@yandex.ru

Vitaly Yasnitsky

Intellect Soft LLC

50 Karpinsky Street, Perm, 614095, Perm Krai

yasnitskiy@mail.ru

Tatyana Mirolubova

Perm State National Research University,

614990, Russia, Perm, Bukireva, 15

mirolubov@list.ru

Leonid Yasnitsky

Perm State National Research University,

614990, Russia, Perm, Bukireva, 15

yasn@psu.ru

Using the example of serial production of steel castings, the possibility of using neural networks as a decision support system to reduce the negative economic consequences

of certain emergency situations related to disruptions in raw material supplies is demonstrated.

Keywords: emergency situation, manufacturing defect, neural network, forecasting, raw material, modeling.

Искусственный интеллект и промышленность

УДК 004.89

АВТОМАТИЗИРОВАННОЕ СОЗДАНИЕ АТТЕСТАЦИОННЫХ МАТЕРИАЛОВ ДЛЯ СОТРУДНИКОВ ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ С ПРИМЕНЕНИЕМ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Зорихин Михаил Петрович

ООО «Академия Бизнес Решений»
614010, Россия, г. Пермь, ул. Героев Хасана, 9а
zorihin@abs95.ru

Кудреватых Виталий Анатольевич

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
kudrevatyh@abs95.ru

Заболотных Алексей Викторович

ООО «Академия Бизнес Решений»
614010, Россия, г. Пермь, ул. Героев Хасана, 9а
zav@abs95.ru

Фофанов Олег Геннадьевич

АО «Пермский завод “Машиностроитель”»
614014, Россия, г. Пермь, ул. Новозвягинская, 57
o-fofanov@pzmash.perm.ru

Пепеляев Михаил Викторович

АО «Пермский завод “Машиностроитель”»
614014, Россия, г. Пермь, ул. Новозвягинская, 57
m-pepelyaev@pzmash.perm.ru

Статья посвящена разработке методики автоматизированного создания аттестационных материалов для сотрудников промышленных предприятий с использованием больших языковых моделей (LLM). Предложенный подход включает сегментацию нормативных текстов, генерацию вопросов различного типа и сложности с применением параметров управления генерацией, а также две стратегии формирования выходных данных: Structured outputs и Schema-Guided Reasoning. Экспериментальная оценка показала, что метод Schema-Guided Reasoning обеспечивает более высокую ясность, практичность и фактическую корректность формулировок по сравнению с традиционным подходом. Таким образом, использование искусственного интеллекта позволяет повысить качество и эффективность оценки квалификации персонала в промышленности.

Ключевые слова: большие языковые модели, автоматизация промышленных предприятий, подготовка аттестационных материалов

Введение. Автоматизация процесса создания аттестационных материалов является одной из ключевых задач в условиях современного развития промышленности. Традиционные методы ручной разработки заданий часто связаны с высокими затратами и отсутствием единого системного подхода, что снижает качество оценки квалификации персонала. Эффективность аттестации напрямую зависит от точности и объективности сформированных заданий.

Актуальность исследования обусловлена расширением масштабов промышленного производства и необходимостью повышения уровня профессиональной подготовки специалистов. Внедрение цифровых технологий способствует автоматизации формирования аттестационных материалов [1]. Применение больших языковых моделей (LLM) позволяет существенно сократить временные затраты и повысить качество создаваемых тестов.

Тем не менее использование таких технологий сопряжено с рядом вызовов. Одним из ключевых является способность LLM генерировать логично связанные и содержательные вопросы [2], соответствующие отраслевой специфике. Несмотря на прогресс в машинном обучении, модели часто испытывают сложности в формировании структурно-вариативных и при этом понятных вопросов.

Цель настоящего исследования – разработка методики автоматизированного формирования аттестационных материалов с применением технологий искусственного интеллекта, направленной на повышение качества и эффективности оценочных процедур на промышленных предприятиях.

Методология. Разрабатываемая методика базируется на использовании больших языковых моделей (LLM) – масштабных нейросетевых систем трансформерной архитектуры, обученных на объемных корпусах текстов, включая общедоступные и специализированные данные. Основная задача моделей – последовательное предсказание следующего токена (слова, части слова или символа) на основе контекста, что обеспечивает формирование связного текста, приближенного к естественному языку и опирающегося на статистические закономерности [3].

Ключевой компонент архитектуры – механизм самовнимания (self-attention) [4], позволяющий определять значимые части входного текста для текущего шага предсказания. В отличие от рекуррентных и сверточных моделей self-attention обеспечивает параллельную обработку всего текста, что позволяет учитывать как локальные, так и длинно-дистанционные связи. Это критично для работы с нормативными и методическими материалами, где правильная интерпретация опирается на широкий контекст.

Архитектура LLM состоит из нескольких слоев [5], реализующих последовательные преобразования текста: начальные слои фиксируют синтаксические зависимости, средние выявляют семантические связи, а верхние формируют абстрактные знания. Благодаря глубине модели возможно построение сложных информационных представлений, способствующих генерации логически выверенных вопросов.

Работа модели регулируется параметрами генерации:

- temperature, управляющим степенью креативности;
- top-k и top-p (nucleus sampling), определяющими диапазон вероятных продолжений;

- max tokens, ограничивающим длину генерируемого текста для предотвращения ошибок и избыточности.

В рамках генерации аттестационных материалов LLM получает на вход сегмент исходного документа и формирует несколько вариантов заданий. Модель способна выделять ключевые понятия, отражающие профессиональные компетенции; преобразовывать текстовые утверждения в вопросы различных типов; варьировать уровень сложности через изменение формулировок и детализацию условий; предлагать варианты ответов, включая правильные и дистракторы.

Особое значение имеет ограничение контекстного окна, определяющее объем доступного для анализа текста. Современные LLM учитывают от нескольких тысяч до сотен тысяч токенов, что позволяет работать как с локальными фрагментами, так и с целыми нормативными документами, повышая универсальность модели.

Таким образом, LLM выступает универсальным генератором оценочных материалов, соединяющим статистические закономерности языка с гибкостью параметров генерации. Это трансформирует статичные документы в динамически формируемые задания, адаптируемые под отраслевую специфику, уровень подготовки сотрудников и требования аттестации.

Для решения поставленной задачи использование LLM интегрировано в последовательный процесс формирования аттестационных материалов, состоящий из трех этапов.

1. Сегментация исходных документов. Тексты нормативных и методических материалов делятся на смысловые фрагменты (от одного до нескольких предложений). Это позволяет локализовать контекст и снизить вероятность избыточности или противоречий при последующей генерации.

2. Выбор сегмента для обработки. Отбор фрагментов может выполняться случайным образом либо по заданным критериям (например, по релевантности ключевым понятиям или профессиональным компетенциям).

3. Генерация вопросов. На основе выбранного сегмента LLM формирует варианты тестовых заданий. Использование языковой модели позволяет варьировать уровень сложности вопросов и обеспечивать разнообразие формулировок.

Стратегии формирования выходных данных. После трех базовых этапов возникает необходимость выбора стратегии формирования конечных результатов, определяющей формат представления и устойчивость системы к ошибкам генерации.

Рассмотрены две принципиально различные стратегии: Structured outputs [6, 8] и Schema-Guided Reasoning [7, 8].

Подход Structured outputs предполагает выдачу результатов в заранее заданной структуре, например в формате JSON, Pydantic-модели или таблицы. Такой фиксированный формат облегчает автоматическую обработку и интеграцию в корпоративные системы, повышает прозрачность и предсказуемость данных, а также снижает риск неоднозначной интерпретации. Тем не менее из-за вариативности генерации LLM возможны отклонения от заданной структуры, требующие дополнительной фильтрации и постобработки, что увеличивает затраты на внедрение.

В противоположность этому Schema-Guided Reasoning использует схему не только для оформления результата, но и как когнитивную опору при генерации. Модель направляется заранее определенной схемой, которая задает тип вопросов, условия формулировок и критерии проверки корректности. Это существенно снижает количество ошибок и повышает согласованность итоговых материалов, однако требует более сложной настройки и увеличивает вычислительные затраты и время генерации.

Проведение эксперимента. Для проверки эффективности рассмотренных стратегий от сотрудников промышленного предприятия, отвечающих за составление материалов для проведения регулярной аттестации работников, были получены регламенты, по которым проводится оценка знаний.

На основе этих нормативных документов были сгенерированы вопросы с использованием обеих стратегий генерации, половина которых создавалась на базе разных фрагментов текста, а другая половина – из одинаковых, что позволило оценить устойчивость моделей к вариативности контекста.

Сформирована таблица для оценивания качества генерации вопросов без указания стратегий, с помощью которых вопросы сгенерированы.

Полученные материалы экспертная группа оценила по трем критериям: ясность формулировки, практическая применимость и фактическая корректность содержания – по шкале от 0 до 3 баллов. Результаты представлены в табл. 1.

Таблица 1

Сравнительный анализ стратегий формирования вопросов

Стратегия	Ясность	Практичность	Фактическая корректность
Structured outputs	1.54	1.23	1.54
Schema-Guided Reasoning	1.85	1.48	2.08

Анализ демонстрирует преимущество Schema-Guided Reasoning по всем критериям с наиболее значительным приростом в фактической корректности. Это подтверждает, что использование схемы как направляющей структуры улучшает качество и согласованность итоговых материалов.

Заключение. В работе представлена методика автоматизированного создания аттестационных материалов для сотрудников промышленных предприятий с использованием больших языковых моделей искусственного интеллекта. Описан процесс сегментации исходных документов, генерации вопросов с вариацией типов и сложности, а также выбор стратегий формирования структурированных выходных данных. Проведенный эксперимент подтвердил преимущество подхода Schema-Guided Reasoning, демонстрирующего более высокую ясность, практическую применимость и фактическую корректность формулировок по сравнению с традиционной стратегией Structured outputs. Полученные результаты свидетельствуют о том, что применение искусственного интеллекта способно существенно повысить качество и эффективность процедуры аттестации, обеспечивая адаптацию материалов к специфике промышленной отрасли и требованиям квалификационной оценки. Разработанная методика может служить основой для дальнейших исследований и внедрений в области цифровизации промышленного обучения и контроля квалификации персонала.

Библиографический список

1. Калимуллина О. В., Троценко И. В. Современные цифровые образовательные инструменты и цифровая компетентность: анализ существующих проблем и тенденций // Открытое образование. 2018. Т. 22, № 3. С. 61–73. DOI [10.21686/1818-4243-2018-3-61-73](https://doi.org/10.21686/1818-4243-2018-3-61-73)
2. Тюгинбаев Д. Д. К вопросу о функционировании языковых моделей: как работает ChatGPT // Искусственный интеллект и большие данные (Big data) в судебной и правоохранительной системе: реалии и требование времени: материалы междунар. науч.-практ. конф., Астана, 19 мая 2023 г. Косшы: Академия правоохранительных органов при Генеральной прокуратуре Республики Казахстан, 2023. С. 96–99. EDN [UJUKKL](https://edn.uju.kk)
3. Зимнуров М. Ф., Астраханцева И. А. Методология создания многосвязных структур данных с применением LLM в рабочих проектах // Современные наукоемкие технологии. Региональное приложение. 2025. Т. 81, № 1. С. 76–83.
4. Бережнов Н. И., Сирота А. А. Регуляризация механизма самовнимания в блоках трансформеров и ее применение в задачах классификации и восстановления изображений // Искусственный интеллект и принятие решений. 2025. № 2. С. 114–129.
5. Павловский Д. В., Кудинов Н. Г. Анализ и декомпозиция архитектуры трансформера в рамках развития генеративно параметрических моделей нейронных сетей // Оригинальные исследования. 2023. Т. 13, № 12. С. 206–210. EDN [CIOPUY](https://edn.cio.ru)
6. Bohra A. et al. WebLists: Extracting Structured Information from Complex Interactive Websites Using Executable LLM Agents // arXiv preprint arXiv:2504.12682 (2025).
7. Chen Y. et al. A schema-guided reason-while-retrieve framework for reasoning on scene graphs with large-language-models (LLMs) // arXiv preprint arXiv:2502.03450 (2025).
8. Rath, A. Structured prompting and feedback-guided reasoning with LLMs for data interpretation // arXiv preprint arXiv:2505.01636 (2025).

AUTOMATED CREATION OF CERTIFICATION MATERIALS FOR INDUSTRIAL ENTERPRISE EMPLOYEES USING ARTIFICIAL INTELLIGENCE TECHNOLOGIES

Zorikhin Mikhail Petrovich

«Academiya Bizness Resheniy», ООО
9a, Geroev Khasana Str., Perm, Russia, 614010
zorihin@abs95.ru

Kudrevatykh Vitaliy Anatolyevich

Perm State University
15, Bukireva Str., Perm, Russia, 61499
kudrevatykh@abs95.ru

Zabolotnykh Aleksey Viktorovich

«Academiya Bizness Resheniy», ООО
9a, Geroev Khasana Str., Perm, Russia, 614010
zav@abs95.ru

Fofanov Oleg Gennadyevich

Perm Machine-Building Plant JSC
57, Novozvyaginskaya Str., Perm, Russia, 614014
o-fofanov@pzmash.perm.ru

Pepelyaev Mikhail Viktorovich

Perm Machine-Building Plant JSC
57, Novozvyaginskaya Str., Perm, Russia, 614014
m-pepelyaev@pzmash.perm.ru

This article is devoted to the development of a methodology for the automated creation of certification materials for employees of industrial enterprises using large language models

(LLMs). The proposed approach includes segmentation of regulatory texts, generation of questions of various types and difficulty levels using controlled generation parameters, as well as two output formation strategies – Structured Outputs and Schema-Guided Reasoning. Experimental evaluation showed that the Schema-Guided Reasoning method provides higher clarity, practicality, and factual accuracy of formulations compared to the traditional approach. Thus, the use of artificial intelligence enables improvement in the quality and efficiency of personnel qualification assessment in industry.

Keywords: large language models, industrial enterprise automation, certification materials preparation

НЕЙРОСЕТЕВАЯ СИСТЕМА ОПРЕДЕЛЕНИЯ ГЕОМЕТРИЧЕСКИХ ПАРАМЕТРОВ НАГРУЖАЮЩИХ СТЕРЖНЕЙ, ИЗГОТОВЛЕННЫХ ПРИ ПОМОЩИ МЕТОДА MCVD, ДЛЯ ВЫТЯЖКИ ВОЛОКОННЫХ СВЕТОВОДОВ

Проскуряков Владислав Сергеевич

Пермский государственный национальный исследовательский университет, ФИТ
614990, Россия, г. Пермь, ул. Букирева, 15
izumrudnimidved@gmail.com

В статье представлено описание разработки нейросетевой системы для определения и прогнозирования геометрических параметров нагружающего стержня, изготовленного при помощи метода MCVD, для вытяжки волоконных световодов. Система позволяет определять овальность сердцевины нагружающего стержня для дальнейшего изготовления оптоволокна с учетом статистических характеристик кварцевой трубы и регулирования расхода газа.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, оптоволокно, волоконный световод, некруглость, преформа-стержень, распределение расхода газа, кварцевые трубы, осаждение труб, сердцевина

Введение. Производство современных оптоволоконных световодов начинается с изготовления высококачественных заготовок, а именно преформ и преформ-стержней. Среди технологий их синтеза доминирующее положение занимает метод MCVD (Modified Chemical Vapor Deposition), или метод модифицированного химического парового осаждения.

Суть метода MCVD заключается в осаждении легированного кварцевого стекла на внутреннюю поверхность вращающейся кварцевой трубки-подложки.

Так как при изготовлении заготовки очень важно не допустить отклонение от прямолинейности заготовки, важно прогнозировать геометрические параметры заготовок [1]. Цель данной работы заключается в создании и обучении нейросетевой модели [2], которая позволит прогнозировать овальность сердцевины преформ-стержней. Результатом исследования является система прогнозирования овальности сердцевины преформы-стержня.

Основная часть. В результате анализа литературных источников [3–5] был определен следующий набор показателей: X1 – Номер станка MCVD, X2 – первый человек, который изготавливал нагружающий стержень, X3 – второй человек, который изготавливал нагружающий стержень, X4 – максимальный диаметр кварцевой трубы, X5 – минимальный диаметр кварцевой трубы, X6 – максимальная толщина стенки, X7 – минимальная толщина стенки, X8 – максимальная овальность изначальной опорной трубы, X9 – минимальная овальность изначальной опорной трубы, X10 – количество бора перед процессом, X11 – количество кремния перед процессом, X12 – количество фосфора перед процессом, X13 – количество проходов подачи и бора, и фосфора, задаваемое технологом, X14 –

количество проходов подачи бора, задаваемое технологом, X15 – количество кремния, задаваемое технологом, X16 – количество фосфора, задаваемое технологом, X17 – количество бора, задаваемое технологом, X18 – позиция от длины нагружающего стержня, D1 – диаметр нагружающего стержня.

Так как все параметры, используемые в данной исследовательской работе, являются числовыми, будем использовать их в начальном виде без кодировки.

Выходной параметр – овальность сердцевины преформы-стержня – будем выводить в числовом виде.

Множество входных данных о статистических характеристиках кварцевой трубы, регулировании расхода газа и реальном значении диаметра было взято с производства. Перед переходом к проектированию и обучению нейросетевой модели [2] была выполнена очистка исходного множества от противоречивых примеров, выбросов, дубликатов [1]. Таким образом, объем итогового множества включает в себя 42 000 примеров. Данное множество было разделено на обучающее, валидационное и тестирующее в соотношении 79, 11, 10% соответственно.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [6] по методике [7]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет восемнадцать входных нейронов, один выходной и один скрытый слой с четырьмя нейронами.

Для оценки корректности работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 100 примеров. Средняя ошибка тестирования составила 3%, что можно считать хорошим результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью значением овальности сердцевины преформы-стержня случайно отобранных 15 преформ-стержней.




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» [6], результат отображен на рис. 2.




Рис. 2. Значимость входных параметров нейросетевой модели

Как видно из рис. 2, наиболее значимыми параметрами являются толщина стенки трубы и овальность трубы перед изготовлением. Также на графике можно видеть, что остальные параметры имеют низкую значимость.

Использование Keras. Далее проведена аналогичная работа с использованием технологии Keras и языка программирования Python [2, 6, 7].

Определено 4 категории: отлично (класс 4, диапазон значений менее 0,1), хорошо (класс 3, диапазон значений менее 0,15), среднее (класс 2, диапазон значений менее 0,2), плохо (класс 1, диапазон значений более 0,2). Для подбора гиперпараметров использована библиотека keras_tuner [8, 9]. Для балансировки датасета используется метод SMOTE [10, 11].

При помощи поиска гиперпараметров лучшая модель имеет три слоя с 128,64,32 нейронами с функцией активации relu. Данная модель обучалась 263 эпохи.

В ходе работы протестированы различные алгоритмы, включая нейронную сеть Keras, а также проведен анализ метрик качества классификации. Полученные результаты представлены в табл. 1.

Таблица 1

Метрики, полученные при помощи Keras, для прогнозирования овальности сердцевины нагружающего стержня

	precision	Recall	f1-score	support
1	0.8631	0.9932	0.9236	292
2	0.9327	1.0000	0.9652	291
3	0.9085	0.9863	0.9458	292
4	0.9950	0.6884	0.8138	292
accuracy			0.9169	1167
macro avg	0.9248	0.9170	0.9121	1167
weighted avg	0.9248	0.9169	0.9120	1167

Общая точность модели составила 0.9169, что свидетельствует о ее хорошей предсказательной способности. Значение F1-score на тестовой выборке подтверждает сбалансированность модели. Для классов 1, 2, 3 модель показывает отличные результаты, что позволяет говорить об идеальном распознавании классов. Класс 4 показал результаты ниже, чем на предыдущих, что связано с пониженным recall.

Нейронная сеть показала F1-score, равную 0.9120, что указывает на минимальное переобучение и является идеальным результатом для модели.

Далее была проверена адекватность модели. На рис. 3 приведен график сравнения прогнозируемых и фактических значений.




Рис. 3. Адекватность нейронной сети овальности сердцевины нагружающего стержня

По итогам тестирования среднеквадратичная ошибка составила 9%.

На рис. 4 представлены значимые параметры, определенные при помощи CatBoost [11, 12]. Наиболее значимым параметром для овальности сердцевины нагружающего стержня стала овальность опорной трубы.




Рис. 4. Значимые параметры овальности сердцевины нагружающего стержня, выполненные при помощи CatBoost

Заключение. Построена система нейросетевого прогнозирования овальности сердцевины преформы-стержня на линии MCVD. Наиболее значимыми параметрами являются толщина стенки трубы и овальность трубы перед изготовлением. Применение такого набора параметров в модели позволяет учитывать внешние факторы с течением времени, а также в дальнейшем она может быть расширена для прогнозирования овальности сердцевины преформы-стержня на других производствах.

Библиографический список

1. Ясницкий Л. Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016.
2. Галушкин А. И. Нейронные сети: основы теории. М: Горячая линия – Телеком, 2012. 496 с.
3. Бурков В. Д., Иванов Г. А. Физико-технологические основы волоконно-оптической техники: учеб. пособие для студ. спец. 200106 Информационно-измерительная техника и технологии и 230100 Информатика и вычислительная техника. М., 2007. 232 с.
4. Ероньян М. А., Мешковский И. К. Основы нанотехнологии анизотропных одномодовых волоконных световодов// Учебное пособие / Санкт-Петербург, 2014. – 80 с.
5. Иванов Г.А., Первадчук В.П. Технология производства и свойства кварцевых оптических волокон: учеб. пособие. Пермь, 2011. 171 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.
7. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Академия, 2005. 176 с.
8. Гумерова Р. С. Построение нейросети средствами языка программирования Python на основе библиотек программных модулей // Математические методы и модели в исследовании современных проблем экономики и общества: сб. ст. Всерос. молодежной науч.-практ. конф. 2014. С. 19.
9. Гниденко А. К., Маслов Е. С., Квасков А. М. Создание простейшей нейросети на языке программирования Python // Тезисы докладов 52-й Междунар. науч.-техн. конф. преподавателей и студентов. 2019. С. 186.
10. Li L., Jamieson K., DeSalvo G., Rostamizadeh A., Talwalkar A. Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization // Journal of Machine Learning Research. 2018. Vol. 18. P. 1–52.
11. Juez-Gil M. et al. Approx-smote: fast smote for big data on apache spark // Neurocomputing. 2021. Vol. 464. P. 432–437.
12. Шуткина Е. В., Курашкин С. О. Применение метода CATBOOST для задачи прогнозирования СХД // Актуальные проблемы авиации и космонавтики: сб. материалов X Междунар. науч.-практ. конф., посвящ. 100-летию акад. М. Ф. Решетнева и Дню космонавтики: в 3 т. Красноярск, 2024. С. 251–253.

NEURAL NETWORK SYSTEM FOR DETERMINING GEOMETRIC PARAMETRS OF PREFORM-ROD CORE ON MCVD LINE FOR DRAWING FIBER OPTICS

Vladislav S. Proskuriakov

Perm State University
15, Bukireva Str., Perm, Russia, 614990
izumrudnimidved@gmail.com

The article describes the development of a neural network system for determining and predicting geometric parametrs of a preform rod on the MCVD line for fibre optic drawing. The system allows the determination the ovality of the cjre of the preform-rod core for further fibre manufacturing, taking into account the statistical characteristics of the quartz tube and gas flow control.

Keywords: artificial intelligence, neural network technologies, prediction, optical fibre, fiber optic light guide, njn-circularity, preform-rod, gas flow rate distribution, quartz pipes, pipe deposition, core

НЕЙРОННЫЕ СЕТИ В ПРОГНОЗИРОВАНИИ БРАКА В ПРОИЗВОДСТВЕННЫХ ПРОЦЕССАХ

Безматерных Глеб Владимирович

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

Актуальная задача повышения эффективности контроля качества продукции в условиях цифровой трансформации промышленности выявила недостаточность традиционных методов статистического и визуального контроля. В настоящей работе рассмотрена тема применения нейронных сетей для прогнозирования дефектов в производственных процессах. Приведен анализ современных архитектур нейросетевых моделей (MLP, CNN, RNN/LSTM), а также обзор практических примеров их использования в различных отраслях промышленности. В работе описаны основные этапы разработки обучающей модели, включая сбор и обработку производственных данных, выбор архитектуры и сравнение с классическими методами прогнозирования. Особое внимание уделено практической значимости внедрения предложенного подхода, позволяющего перейти от фиксирующего контроля к проактивному управлению качеством.

Ключевые слова: нейронные сети, прогнозирование брака, контроль качества, цифровая трансформация.

Введение. Современные предприятия функционируют в условиях высокой конкуренции и возрастающих требований к качеству продукции. Одной из важнейших задач является снижение процента брака, напрямую влияющего на себестоимость и репутацию компании. Традиционные методы контроля – визуальный осмотр и статистический анализ – не позволяют эффективно выявлять скрытые дефекты и прогнозировать их возникновение.

В связи с этим возрастает интерес к интеллектуальным системам, использующим методы машинного обучения и анализа больших данных. Цель исследования заключается в создании нейросетевой модели для предсказания дефектов, которая позволит повысить точность прогнозирования и сократить производственные издержки. Для достижения поставленной цели решаются следующие задачи: анализ существующих методов прогнозирования брака, разработка и обучение нейросетевой модели, сопоставление ее эффективности с классическими методами и исследование возможности внедрения в реальные производственные циклы.

Применение нейронных сетей в промышленности. Нейросетевые технологии находят применение в машиностроении (прогнозирование износа оборудования по вибрационным характеристикам), электронике (выявление микродефектов микросхем), металлургии (оценка свойств стали в зависимости от состава и режимов обработки), химической промышленности (прогноз выхода продукта по условиям реакции). В текстильной промышленности нейронные сети используются для прогнозирования спроса и оптимизации запасов. Отдельное направ-

ление – компьютерное зрение для автоматизированной инспекции поверхности изделий, где CNN демонстрируют высокую точность при обнаружении трещин, сколов и других дефектов. Кроме того, в пищевой промышленности нейронные сети применяются для оценки качества мясных продуктов и прогнозирования сроков хранения. В металлургии исследователи отмечают успешное использование моделей для контроля состава сплавов и прогнозирования механических свойств в зависимости от режимов термообработки. Таким образом, спектр применения нейросетевых технологий охватывает широкий круг производственных задач, от анализа изображений до прогнозирования временных рядов параметров технологических процессов.

На основе подобных примеров можно определить, какие нейронные сети могут быть использованы в ходе работы производства, и применить их на практике. Для задач, не требующих комплексных вычислений, можно начать с базовой модели – перцептрона, решающего задачи линейной классификации. Его развитие – многослойный перцептрон (MLP), способный моделировать нелинейные зависимости. Сверточные нейронные сети (CNN) оптимальны для обработки изображений, что особенно важно при автоматической визуальной инспекции продукции. Рекуррентные нейронные сети (RNN) применяются для анализа временных рядов, например технологических параметров. Модификация LSTM обеспечивает устойчивость к проблеме исчезающего градиента и позволяет учитывать длительные зависимости. Перспективным направлением являются генеративно-состязательные сети (GAN), используемые для синтетического расширения данных, что особенно актуально при недостатке примеров дефектов.

Обзор литературы. В зарубежных работах широко освещено применение нейросетей в промышленности. Например, в исследовании дефектов алюминия с помощью импульсной термографии достигнута точность 99% [1]. В другой статье описывается использование алгоритма распространения пчел для оптимизации сети при выявлении дефектов древесины [2]. Существенный массив публикаций посвящен прогнозированию проницаемости бетона с применением многослойных сетей [3–6]. В работе [7] рассматривается метод обнаружения дефектов яблок с помощью неглубоких сетей и анализа главных компонент, где точность составила 89,9%. В [8] изучалось влияние дефектов, возникших при лазерной порошковой плавке, на долговечность металлических сплавов, где модель в связке с компьютерной томографией достигла коэффициента детерминации 0.99. В российских исследованиях отмечается создание моделей для прогнозирования качества патронов [9], контроля выпуска пищевой продукции [10], оценки влияния химического состава стали на свойства рельсов [11], прогнозирования качества сплавов [12], а также разработки цифровых двойников технологических процессов [14]. Например, в работе [13] предложена нейросетевая модель для выявления причин брака литых лопаток газотурбинных двигателей с точностью прогноза 95%. Эти исследования показывают, что применение нейросетевых алгоритмов охватывает широкий спектр задач, от анализа химического состава до мониторинга параметров оборудования.

Методология и значимость результатов. Построение нейросетевой модели включает несколько этапов: формирование выборки данных (структуриро-

вание и предварительная обработка), выбор признаков, разработку архитектуры модели, обучение и тестирование. Для оценки точности применяются метрики, основанные на среднеквадратичной ошибке или кросс-энтропии в зависимости от задачи (регрессия или классификация). Валидация проводится на реальных производственных данных, что позволяет сопоставить эффективность с классическими статистическими методами. Особое внимание уделяется проблемам интерпретации моделей и необходимости разработки интерфейсов для технических специалистов.

Применение нейросетевых алгоритмов позволяет перейти от фиксирующего контроля к проактивному управлению качеством. Модель обеспечивает выявление потенциальных отклонений на ранних стадиях технологического процесса. Это снижает уровень брака, уменьшает затраты и повышает производительность. Практическая значимость заключается в возможности интеграции предложенного подхода в системы управления качеством на производственных предприятиях. Внедрение позволит автоматизировать контроль, повысить точность прогнозов, снизить затраты на переработку и повысить конкурентоспособность в условиях Индустрии 4.0. Кроме того, нейросетевые модели обладают способностью к адаптации: они могут переобучаться при изменении условий (новое сырье, модернизация оборудования), что делает их гибкими и экономически эффективными.

Заключение. Использование нейронных сетей в прогнозировании брака открывает новые перспективы для промышленности. Обзор литературы показывает, что нейросети успешно применяются как за рубежом, так и в России для прогнозирования качества продукции в машиностроении, металлургии, химической и пищевой промышленности. Методология, основанная на глубоком обучении и современных алгоритмах оптимизации, обеспечивает высокую точность прогнозов. Практическая значимость заключается в возможности перехода от традиционного контроля к интеллектуальным системам управления качеством, что ведет к снижению брака, росту производительности и укреплению позиций предприятий на рынке. Дальнейшие исследования могут быть направлены на расширение функциональности моделей, повышение их интерпретируемости, а также разработку универсальных решений для цифровых двойников производственных процессов.

Финансирование. Работа выполнена при поддержке гранта Российского научного фонда № 22-61-00096, <https://rscf.ru/project/22-61-00096/> Главным исполнителем гранта является Национальный исследовательский университет «МЭИ».

Библиографический список

1. Vallerand S., Maldague X. Defect characterization in pulsed thermography: A statistical method compared with Kohonen and Perceptron neural networks // NDT and E International. 2000. Vol. 33. P. 307–315.
2. Pham D. T., Soroka A. J., Ghanbarzadeh A., Koc E., Otri S., Packianather M. Optimising Neural Networks for Identification of Wood Defects Using the Bees Algorithm // 4th IEEE International Conference on Industrial Informatics. 2006. P. 1346–1351
3. Boğa A. R., Öztürk M., Topçu İ. B. Using ANN and ANFIS to predict the mechanical and chloride permeability properties of concrete containing GGBFS and CNI // Composites Part B: Engineering. 2013. Vol. 45. P. 688–696.

4. Ghafoori N., Najimi M., Sobhani J., Aqel M. A. Predicting rapid chloride permeability of self-consolidating concrete: A comparative study on statistical and neural network models // *Construction and Building Materials*. 2013. Vol. 44. P. 381–390.
5. Inthata S., Kowtanapanich W., Cheerarot R. Prediction of chloride permeability of concretes containing ground pozzolans by artificial neural networks // *Material and Structures*. 2013. Vol. 46. P. 1707–1721.
6. Yasarer H., Najjar Y. M. Characterizing the Permeability of Kansas Concrete Mixes Used in PCC Pavements // *International Journal of Geomechanics*. 2014. Vol. 14.
7. Unay D. Apple defect detection and quality classification with mlp-neural networks. 2002.
8. Bao H., Wu S., Wu Z., Kang G., Peng X., Withers P. J. A machine-learning fatigue life prediction approach of additively manufactured metals // *Engineering Fracture Mechanics*. 2021. Vol. 242.
9. Тарасова Н. А., Лялин В. М., Пантюхин О. В. Метод применения искусственных нейронных сетей для прогнозирования параметров качества патронов / *Известия Тульского государственного университета. Технические науки*. 2011. Вып. 2. С. 336–342.
10. García-Esteban J. A., Curto B., Moreno V., Martín B. Quality Control Monitoring by using Artificial Neural Networks for an Iberian Ham Industry // *International Conference on Informatics in Control, Automation and Robotics*. 2018.
11. Машеков С. А., Абсадыков Б. Н., Алимкулов М. М. Влияние химического состава стали 76ф на качество рельсов // *Современные проблемы науки и образования*. 2015. № 2-2. С. 1–8.
12. Горюхин А. С., Христолюбов В. Л., Сусенков А. Г., Нургаянова О. С. Прогнозирование качества сплавов по химическому составу в системе ERP // *Вестник УГАТУ*. 2009. Т. 12, № 2. С. 83–87.
13. Голдобин М. А., Морозов А. А., Ясницкий Л. Н. Нейросетевое прогнозирование и управление качеством литейных изделий // *Материалы XIII Международной конференции по прикладной математике и механике в аэрокосмической отрасли (АММАГ'2020)*. 2020. С. 640–641.
14. Ясницкий Л. Н., Мезенцев А. С. Об управлении химическим составом сырьевого материала и режимом плавки для обеспечения требуемых механических свойств стальных изделий серийного производства // *Прикладная математика и вопросы управления*. 2023. № 3. С. 109–126.

NEURAL NETWORKS IN DEFECT PREDICTION IN MANUFACTURING PROCESSES

Gleb V. Bezmaternykh

Perm State University
15, Bukireva Str., Perm, Russia, 614990
dombrin@yandex.ru

The paper examines the use of neural networks for defect prediction in serial production processes. Traditional quality control methods are losing their effectiveness as technological processes become more complex. The purpose of the study is to develop and test a defect prediction model based on deep learning methods. The paper provides an overview of existing research, describes the methodology for building and training the model, and compares its performance with classical statistical approaches. Particular emphasis is placed on the practical significance of integrating the proposed approach into real manufacturing processes to reduce defect rates, optimize costs, and increase competitiveness.

Keywords: neural networks, defect prediction, quality control, digital transformation

ПРЕДИКТИВНАЯ АВТОМАТИЧЕСКАЯ СИСТЕМА ДЕТЕКЦИИ ПОВРЕЖДЕНИЙ КОНВЕЙЕРНЫХ ЛЕНТ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Зотина Галина Витальевна

Институт компьютерных наук и технологий
при Пермском государственном национальном исследовательском университете
614990, Россия, г. Пермь, ул. Букирева, 15
pastuhova13@yandex.ru

Жабо Дмитрий Владимирович

Институт компьютерных наук и технологий
при Пермском государственном национальном исследовательском университете
614990, Россия, г. Пермь, ул. Букирева, 15
sekrittt@vk.com

Алексеев Артем Вадимович

Институт компьютерных наук и технологий
при Пермском государственном национальном исследовательском университете
614990, Россия, г. Пермь, ул. Букирева, 15
artem-alekseev-04@internet.ru

Рассматривается задача распознавания (обнаружение или детекция объекта) и классификации повреждений конвейерных лент резиноканевого и резиноклассового типа общего назначения. Данная задача относится к области неразрушающего контроля, который решает следующие задачи: получить первичную информацию об имеющихся дефектах, их морфологии, природе возникновения, количестве, размерах, местоположении. Анализируются существующие методы задачи детекции в зависимости от «области интереса», затронуты проблемы методологии и терминологии технологии распознавания. Особый акцент сделан на проблему «бедности» наборов реальных данных. Рассмотрены пути решения указанной проблемы посредством симуляции физических процессов за счет применения межплатформенной среды Unity, а также возможности авторазметки данных посредством масок в среде Blender.

Ключевые слова: алгоритмы детекции объектов и их классификации, распознавание образов, повреждения стальных тросов, авторазметка, среда Unity, среда Blender

Введение. Экономическая эффективность работы предприятий в значительной степени зависит от технического состояния, грамотной эксплуатации и обслуживания оборудования с минимизацией времени и средств на устранение неисправностей. В настоящее время значительную часть себестоимости некоторых видов продукции составляют расходы на его транспортировку, что делает актуальным поиск резервов повышения эффективности использования таких транспортных систем, как ленточные конвейеры. Технические возможности и показатели работы, а также ресурс каждого типа оборудования определяются проектной и конструкторской документацией. В соответствии с суммарной наработкой

ленточного конвейера от начала его эксплуатации до перехода в предельное состояние определяется как ресурс, который тесно связан со сроком службы. Предельное состояние – это состояние объекта, при котором его дальнейшая эксплуатация недопустима или нецелесообразна, при этом достичь предельного состояния можно по разным причинам: дальнейшее применение становится недопустимым по требованиям безопасности, неэкономичным, неэффективным и т.д. При этом календарная продолжительность эксплуатации может варьироваться, поскольку зависит от ряда факторов: эксплуатационных нагрузок, конструктивных особенностей, организации обслуживания и ремонта технических устройств. Поддержание соответствия конвейеров требованиям промышленной безопасности зависит от рациональной организации обслуживания и ремонта. На практике же межремонтные сроки планируются исходя из календарного времени эксплуатации, не учитывается фактическая наработка, интенсивность нагрузок. Сложилась недостаточно совершенная и требующая значительных трудовых и финансовых затрат система: капитальный ремонт производится без достаточных оснований и в большем объеме, чем это требуется, лишь на основании срока службы; либо наблюдается абсолютно противоположная тенденция: техническое устройство попадает в ремонт только после потери работоспособности, т.е. отказа. Несвоевременная замена изношенных деталей увеличивает вероятность аварийных ремонтов. Наиболее перспективной стратегией обслуживания и ремонта ленточных конвейеров на сегодняшний день представляется обслуживание по фактическому состоянию, поскольку предельные состояния конструкций являются результатом постепенного накопления повреждений в деталях, узлах и элементах, наиболее дорогостоящий элемент подобных устройств – это непосредственно лента, чья цена составляет около 40% от всей конструкции [5]. Выявить и устранить дефекты ленты на начальной стадии развития, обеспечив минимизацию ремонтных работ, возможно только при внедрении эффективных методов диагностирования, к таким методам относятся и системы детекции на основе машинного зрения.

Согласно методическим указаниям по проведению экспертизы промышленной безопасности ленточных конвейерных установок (РД-15-04-2006), лента не должна иметь:

- продольных сквозных повреждений длиной более 100 мм;
- поперечных сквозных повреждений и надрывов боковых кромок резинотканевой ленты длиной более 20 мм;
- более 10 поврежденных тросов на длине 1 м резинотросовой ленты;
- износа или расслоения боковой кромки более чем на 5% от номинальной ширины ленты;
- отслоения обкладок или обнажения тканевого каркаса более чем на 15% площади на длине 1 м резинотканевой ленты или более чем на 5% всей ее поверхности;
- поврежденных стыковых соединений.

Классификация повреждений. При решении задач неразрушающего контроля технологией машинного зрения есть следующая специфика: даже при нали-

ции достаточного набора данных, в данном случае изображений повреждений, почти всегда есть риск появления такого повреждения, которое вне датасета, что резко снижает эффективность подобных систем. В связи с этим приходится, помимо сверточных сетей, обученных на повреждения, про которые есть информация (описание или фотографии), добавлять в такие системы нейронно-экспертные сети, которые фиксируют нарушения геометрий (внешних или внутренних), цветовых стандартов и иных, возможных к детекции, параметров. Например, при детекции повреждений стального троса (каната) сами повреждения были классифицированы как повреждения внешней и внутренней геометрий свивки, а нейронно-экспертная сеть была реализована за счет системы эталонов этой свивки [6].

Была разработана следующая классификация повреждений.

Нарушение внутренней геометрии:

- продольных сквозных повреждений длиной более 100 мм;
- поперечных сквозных повреждений и надрывов боковых кромок резиноканавной ленты длиной более 20 мм;
- более 10 поврежденных тросов на длине 1 м резинотросовой ленты;
- отслоения обкладок или обнажения тканевого каркаса более чем на 15% площади на длине 1 м резинотканевой ленты или более чем на 5% всей ее поверхности;

- поврежденных стыковых соединений.

Нарушение внешней геометрии:

- износа или расслоения боковой кромки более чем на 5% от номинальной ширины ленты;
- отслоения обкладок или обнажения тканевого каркаса более чем на 15% площади на длине 1 м резинотканевой ленты или более чем на 5% всей ее поверхности;
- поврежденных стыковых соединений.

Стоит отметить, что ряд повреждений может относиться к двум типам повреждений в зависимости от факта фиксации изображения: если повреждение на изображении не нарушает внешние границы изображения (проекция ленты на данном снимке), то повреждение относится к внутренним повреждениям, если же обрыв или иное повреждение зафиксировано на границе изображения, то к внешним. Внутренние повреждения фиксируются за счет формирования эталона проекции ленты, отклонения от площадей и «направляющих» эталона.

Также необходимо отметить, что автоматизация процесса детекции позволит анализировать и причины появления тех или иных повреждений. Подобный функционал при достаточном наборе данных позволит говорить об аналитике повреждений, что, в свою очередь, влечет предиктивность создаваемой системы.

Данные в задаче представлены классическим для технологии машинного зрения образом – в виде цветных RGB-снимков. На каждом снимке может как присутствовать сразу несколько дефектов, так и не присутствовать вовсе.

Задача распознавания образов на изображения логически подразделяется на две подзадачи:

- нахождение и выделение «области интереса» (некое контурирование области на изображении, форма и способ которого зависит от объекта, алгоритма и пр.);
- классификация объекта в «области интереса».

В зависимости от формы области интереса дальнейшая детекция возможна в виде ограничивающих прямоугольников, многоугольников, битовых масок, точек интереса и пр. Сущностно важны топология области интереса (ее форма, площадные зависимости и пр.) и/или особенности координатных зависимостей «особых» точек. Порой сложно разделить шаги выделения «области интереса» и детекцию объекта внутри нее, ибо одно порой однозначно определяет второе.

В нашей задаче были выбраны ограничивающие прямоугольники, но эксперименты с многоугольными областями также проводились.

Помимо формы предсказания, необходимо было определить формат датасета (способ организации данных и аннотаций), остановились на MS COCO и YOLO 11.

Особо интересные результаты были получены при обнаружении проблемы «бедности» датасетов, а именно: поймать даже зачаточный процесс появления некоторых повреждений в режиме реального времени порой невозможно – их там попросту нет. Данные пришлось синтезировать следующим образом:

- средствами полигонального моделирования были воссозданы сцены и объекты в среде Blender с использованием скриптов на языке Python, исключение составила программа преобразования растровой разметки в формат YOLO 11, написанная на языке Rust;

- модели конвертировались в среду Unity, где была реализована физика ряда повреждений.

Подобный подход позволяет говорить об авторазметке данных за счет масок некоторых участков синтезируемых объектов.

Библиографический список

1. Абрамов В. И. Метод опорных точек для обучения распознаванию образов в произвольных метрических пространствах: дис. ... канд. физ.-мат. наук. 2014. 84 с.
2. Журавлев Ю. И., Рязанов В. В., Сенько О. В. Распознавание. Математические методы. Программная система. Практические применения. М.: Фазис, 2005. 159 с.
3. Кропотов Ю. И., Жуков Е. М., Лугинин И. А., Полошков С. И. Основные причины снижения срока эксплуатации ленточных конвейеров // Молодой ученый. 2015. № 23 (103). С. 172–175. URL: <https://moluch.ru/archive/103/24018/> (дата обращения: 27.07.2025).
4. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Академия, 2005. 176 с.
5. Контроль продольного разрыва конвейерной ленты // ТЕКО. URL: <https://teko-com.ru/belye-knigi/vazhnost-kontrolya-prodolnogo-razryva-lenty-konvejera.html> (дата обращения: 15.09.2025).
6. Пастухова Г. В., Зотин Д. А., Патакина А. С., Патакин И. Н. Предиктивная система детекции повреждений стальных тросов лифтов гражданского назначения на основе нейронных сетей // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Седьмой всерос. науч.-практ. конф. с междунар. участием «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века», г. Пермь, 20–21 октября 2021 г. / под ред. Л. Н. Ясницкого. Пермь, 2021. С. 235–242.

PREVENTIVE AUTOMATIC DETECTION SYSTEM DAMAGES OF STEEL CABLES OF CIVIL PURPOSE ELEVATORS BASED ON NEURAL NETWORKS

Zotina Galina Vitalievna

Institute of Computer Science and Technology at Perm State National Research University
15, Bukireva Str., Perm, Russia, 614990
pastuhova13@yandex.ru

Zhabo Dmitry Vladimirovich

Institute of Computer Science and Technology at Perm State National Research University
15, Bukireva Str., Perm, Russia, 614990
sekrittt@vk.com

Alekseev Artem Vadimovich

Institute of Computer Science and Technology at Perm State National Research University
15, Bukireva Str., Perm, Russia, 614990
artem-alekseev-04@internet.ru

The problem of recognition (detection or detection of an object) and classification of damage to a steel cable in civil elevators is considered. The existing methods of the detection problem are analyzed depending on the “area of interest,” the problems of methodology and terminology of the recognition technology are touched upon. Particular emphasis is placed on the problem of “poverty” of real data sets. The ways of solving the above problem by means of simulation of physical processes through the use of the cross-platform Unity environment, as well as the possibility of auto-tagging data using masks in the Blender environment are considered.

Keywords: algorithms for detecting objects and their classification, pattern recognition, damage to steel cables, auto-tagging, Unity environment, Blender environment

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ДЛЯ ОЦЕНКИ КАЧЕСТВА ЛИТЬЯ И УДАРНОЙ ВЯЗКОСТИ МЕТАЛЛА

Мезенцев Алексей Сергеевич

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
alexey537@yandex.ru

В статье приведены результаты разработки и применения систем искусственного интеллекта на металлургическом предприятии. Показаны положительные эффекты от их внедрения.

Ключевые слова: дефект при плавке металла, качество, брак, компьютерный эксперимент, химический состав, сырьевой материал

Введение. В последние годы наблюдается существенный рост интереса к внедрению методов искусственного интеллекта для решения сложных производственных и технологических задач в металлургии. Качество литья и механические свойства, в том числе ударная вязкость, определяют долговечность, эксплуатационную надежность и стоимость конечной продукции. Традиционные эмпирические методы оценки, основанные на решении краевых задач математической физики [1, 2], на современном уровне развития производства становятся недостаточно эффективными: требуется анализ десятков технологических и химических параметров, осуществляемый в реальном времени.

Актуальность исследования связана с необходимостью повышения достоверности контроля и управления литьем на этапе затвердевания и охлаждения. Применение искусственных нейронных сетей (ИНС) позволяет выявлять сложные нелинейные связи между составом, режимами плавки и свойствами изделия, минимизируя влияние человеческого фактора и ошибки замеров [3–6]. Далее будет изложен поход к созданию нейросетевой модели на основе исследования датасетов плавки стали.

Постановка задачи и формирование DataSet. Исходная база данных создана на основе информации о 906 партиях стали: по каждой партии зафиксированы параметры плавки и разливки, температурные и временные режимы, химический состав по Mn, P, S, Si, Cr, Ni, Cu, Al и ряду других элементов, сведения по микроструктуре и значениях ударной вязкости. Всего известно более 120 признаков. Проведена очистка данных, замена аномалий, нормализация количественных признаков. Были выделены целевые переменные: значения KCV-60 при различных температурах, бинарные признаки дефектности партии, оценки экспериментаторов. Проанализированы распределения исходных признаков и выбраны наиболее информативные (например, содержание Mn, Si, P, величины зерна, скорость охлаждения).

Подготовленный датасет использован для создания нейросетевой модели.

Проектирование, обучение и тестирование нейросети. С использованием подготовленного датасета и «Нейросимулятора 1.0» были разработаны:

- многослойная полносвязная сеть (3 скрытых слоя, 4–16 нейронов в каждом; функция активации ReLU, оптимизатор Adam);
- варианты обучения – эпохи от 50 до 400, стратифицированная перекрестная валидация;
- распределение на обучающую, валидационную и тестовую выборки в пропорции 70/15/15 соответственно.

Результаты и анализ экспериментов. Далее в программном инструменте «Нейросимулятор 1.0» была создана нейронная сеть прямого распространения слоистой структуры, представленная на рис. 1.




Рис. 1. Архитектура используемой нейронной сети, созданная в программном инструменте «Нейросимулятор 1.0»

На тестовом множестве из 150 примеров, не использовавшихся в обучении, нейронная сеть показала результаты тестирования, представленные на рис. 2 в виде сопоставления данных заводских замеров ударной вязкости KCV-60 °C и соответствующих значений нейросетевых прогнозов.




Рис. 2. Сопоставление результатов заводских замеров ударной вязкости с прогнозами нейросети на фрагменте тестового множества примеров

Из результатов тестовых испытаний, приведенных на рис. 2 и в табл. 1, видно, что, несмотря на существенную погрешность (как следует из рис. 2), нейронная сеть в целом правильно выполняет прогнозы заводских замеров ударной вязкости. Из чего обоснованно можно сделать вывод об адекватности разработанной нейросетевой модели исследуемому технологическому процессу.

Таблица 1

Статистические метрики качества нейросетевой модели

Наименование	Выражение	Значение
Средняя абсолютная ошибка	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	30,3 ед.
Средняя абсолютная процентная ошибка (средняя относительная погрешность)	$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{ y_i }$	12%
Коэффициент детерминации	$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2}$	0,54

Полученные показатели превосходят результаты аналогичных регрессионных моделей без глубокого обучения.

Серия виртуальных компьютерных экспериментов при помощи созданной нейросетевой модели показывает дефекты и брак при плавке стали, а также прогнозирует ударную вязкость KCV-60 °С.

Первый эксперимент проводился для оценки значимости параметров.

На рис. 3 с помощью ПО «Нейросимулятор 5.0» построена гистограмма оценки значимости входных параметров нейронной сети по отношению к ударной вязкости изготавливаемого изделия. Как видно из результатов, наиболее значимыми параметрами, в наибольшей степени влияющими на ударную вязкость изделий, являются «Продолжительность Кипа», «Содержание фосфора», «Суммарное содержание фосфора и серы», «Скорость %» и т.д. Наименее значимыми являются «Содержание серы по расплаву», «Содержание кремния в шлаке», «Общий тоннаж металла», «Окись железа в шлаке» и т.д.




Рис. 3. Значимость входных параметров нейронной сети по отношению к ударной вязкости KCV-60 °С

Второй эксперимент проводился для выявления влияния параметра «Продолжительность Кипа». Проводилась серия расчетов, получены значения ударной вязкости, которые на рис. 2 выделены овалами.

Заключение. Искусственные нейронные сети доказали свою эффективность для оценки ударной вязкости и качества литья стали. Реализована масштабная система обучения на реальных производственных данных, показавшая устойчивость, высокую точность и применимость в промышленных условиях. Перспективы дальнейших исследований: добавление объяснимых моделей, интеграция с большими языковыми и графовыми сетями, расширение на прогноз других механических свойств.

Финансирование. Создание моделей производственного процесса выполнено за счет гранта Российского научного фонда № 22-61-00096, <https://rscf.ru/project/22-61-00096/> Головным исполнителем гранта является Национальный исследовательский университет «МЭИ».

Эксперименты над нейросетевыми моделями выполнены при поддержке Фонда содействия развитию малых форм предприятий в научно-технической сфере (Россия), заявка № С1-231505 «Нейросетевая система прогнозирования брака литейных изделий и оптимального выбора параметров технологических процессов их производства».

Библиографический список

1. Самойлович Ю. А., Ясницкий Л. Н. Сопряженная задача теплообмена, гидродинамики и затвердевания расплава // Инженерно-физический журнал. 1981. Т. 41, № 6. С. 1109–1118.
2. Ясницкий Л. Н. Метод фиктивных канонических областей в механике сплошных сред. М.: Наука: Физматлит, 1992. 128 с.
3. Ясницкий Л. Н., Голдобин М. А. Мезенцев А. С. Программные инструментальные средства для разработки мероприятий по снижению брака серийного производства // Прикладная математика и вопросы управления. 2025. № 2. С. 99–116. DOI 10.15593/2499-9873/2025.2.07
4. Ясницкий Л. Н., Мартыненко С. В., Поленова А. С., Мезенцев А. С. Искусственный интеллект для снижения брака отливок // Литейное производство. 2025. № 7. С. 35–41. URL: <https://cloud.mail.ru/public/TzqW/DaSiylHzp>
5. Ясницкий Л. Н., Голдобин М. А. Нейросетевое прогнозирование дефектов производства металлургической продукции // Прикладная информатика. 2024. Т. 19, № 1 (109). С. 113–124. DOI 10.37791/2687-0649-2024-19-1-113-124
6. Ясницкий Л. Н., Мезенцев А. С. Об управлении химическим составом сырьевого материала и режимом плавки для обеспечения требуемых механических свойств стальных изделий серийного производства // Прикладная математика и вопросы управления. 2023. № 3. С. 109–126. DOI 10.15593/2499-9873/2023.3.08

ARTIFICIAL INTELLIGENCE FOR ASSESSING CASTING QUALITY AND METAL IMPACT TOUGHNESS

Aleksey Sergeevich Mezentsev

Perm State University,
15, Bukireva Str., Perm, Russia, 614990
Alexey537@yandex.ru

Modern challenges in metallurgy demand advanced methods for evaluating the quality and mechanical properties of products, especially impact toughness and casting structure. This

paper proposes and implements an artificial neural network approach for predicting KCV-60 impact toughness and comprehensive casting quality assessment based on industrial data. Testing on a dataset of 906 steel batches (with over 120 technological and chemical features) demonstrated that the developed neural network achieved a mean absolute error below 6.8 and a determination coefficient (R^2) of about 0.66. The models efficiently reveal hidden dependencies between chemical composition, melting parameters, and material properties, enabling prediction of output characteristics at the production stage. The study emphasizes the high practical value of implementing such systems for automated quality control in the metallurgical industry.

Keywords: artificial intelligence, neural network technologies, forecasting, urban real estate, primary real estate market, forecasting the value of real estate

ФОРМАЛИЗАЦИЯ ЭКСПЕРТНЫХ ПАРАМЕТРОВ ЕДИНИЧНОГО ИЗДЕЛИЯ

Нихамкин Леонид Шмерович

ООО «СК-СЕРВИС»

614068, Россия, г. Пермь, ул. Ленина, 15

Leonid1555@yandex.ru

В статье представлена разработка способа формализации более 20 экспертных параметров дорогостоящего единичного изделия для поиска причин его поломки.

Ключевые слова: анализ, формализация, экспертные параметры, изделие, труднораскрываемый, поломка, признак, весовой коэффициент, логические связи, прочность, материал, дорогостоящий, энергоемкий

Введение. Поиск причин труднораскрываемых скрытых поломок дорогостоящих энергоемких изделий является одной из актуальных задач современного машиностроения. Данная работа может существенно помочь в разработке изделий и в широкой адаптации к ИИ любых объектов путем экспертной формализации признаков и применения ценного докомпьютерного опыта. В современной технической литературе работ по представленным способам не найдено.

Выполнен анализ поломки дорогостоящей экспериментальной сервисной установки на ТЭЦ с приводом от электродвигателя.

Разработана малая база данных (БД). Экспертно назначено множество параметров для исследования. Ввиду того что изделие в одном экземпляре, был выполнен экспертный анализ по каждому из более чем 20 параметров. Результат подтвержден с помощью формализации параметров. Найдена причина поломки.

Основная цель работы состоит в выявлении скрытой причины поломки изделия. Конечный результат – устранение причины поломки изделия.

Постановка задачи. При единичном изделии для анализа причины отклонения в его работе выбираем две смежные детали ротора и статора по результатам инструментального обследования.

Разрабатываем малую БД изделия. Для компенсации малого числа изделий выбрано наибольшее количество разрозненных параметров – признаков изделия. Исследован подробно каждый из следующих параметров: геометрические размеры и отклонение формы, изменение температуры и свойств материалов, поверхностные дефекты деталей, износ, внутренние напряжения, натяги или зазоры, запасы прочности в разных участках деталей при различных температурах и другие. Данные параметры измерены до эксплуатации изделия, во время его работы и после его остановки.

Результат анализа: выявлена причина поломки изделия.

Проектирование и тестирование способов анализа. Для данных деталей изделия выполнен анализ влияния параметров на поломку с помощью двух разработанных способов.

Способ № 1, экспертный. На основании малой базы данных деталей выполнено экспертное исследование отклонения от нормы каждого признака в отдельности и по сравнению с аналогичным исправным изделием. Исследование выполнено различными методами, а именно экспериментом, по имеющемуся опыту, по новым и по имеющимся исследованиям, по ответам специалистов и экспертов. Множество параметров разделены на группы и подгруппы и представлены в виде таблицы: специфические, существенные и несущественные в соотношении 2, 30, 68% соответственно, определено их логическое взаимодействие, результаты обобщены в выводы.

При этом явных признаков влияния данных параметров на поломку выявлено не было. Потребовались более глубокие дополнительные исследования. В результате найдена причина поломки: неточно определена температура в нижней точке детали № 2 во время эксплуатации изделия, что при проектировании не было учтено.

Способ № 2, формализация. Для проверки выполнена формализация с построением таблицы (табл. 1), где столбцы – это изделие и его аналог X_1, X_2 , а строки $Y_1...Y_7$ – параметры одной детали. В каждой ячейке таблицы $X_i Y_j$ поставлен весовой коэффициент отклонения каждого признака от нормы от 0 до 1, который назначили по результатам способа № 1. То же выполнено по аналогичному изделию. У аналога в ячейке параметра Y_7 ($X_2 Y_7$) коэффициент равен 1. Далее выполнено более подробное изучение параметра Y_7 ($X_1 Y_7$) у данного изделия, подтвердился вывод, полученный в способе № 1.

Следовательно, оба разработанных способа показали свою эффективность. Для максимальной достоверности полученных результатов последовательно применены оба способа анализа.

Таблица 1

Результат тестирования способом формализации

Параметр	Обозначение	Весовой коэффициент, 0...1		
		Изделие № 1 (X_1)	Аналог изделия (X_2)	Вывод. Сумма коэффициентов
Геометрические размеры до работы изделия	Y_1	0	0,2	0,2
Геометрические размеры в работе.	Y_2	0,2	0	0,2
Геометрические размеры после работы	Y_3	0,4	0,3	0,7
Отклонение формы до работы	Y_4	0	0,1	0,1
Отклонение формы в работе	Y_5	0,3	0	0,3
Отклонение формы после работы	Y_6	0,2	0,5	0,7
Температура в нижней точке детали № 2	Y_7	1	1	2

Как указано, самый значимый параметр – температура в нижней точке детали № 2 в процессе работы ($X_1 Y_7$).

Заключение. В результате исследования разработана малая БД из более чем 20 параметров – признаков деталей дорогостоящего единичного изделия оборудования ТЭЦ. Необходимые параметры выбраны экспертом.

Определена скрытая первопричина поломки единичного изделия. Разработаны два способа анализа малой БД: экспертный, каждый из более чем 20 параметров в отдельности проанализирован по опыту подробно, логически выделен специфический признак – первопричина поломки; формализация – для проверки составлена таблица с весовыми коэффициентами. Данный алгоритм анализа может применяться для проектирования ИИ при накоплении новых данных.

Для анализа каждого из параметров возможно проработать использование и других методов, а именно математической логики, математической статистики, теории вероятности.

Исходя из результатов исследования, малая БД и предложенные способы работают корректно. Возможно применение предложенных способов в машиностроительном производстве единичных изделий, в широком спектре любых практических задач, для формализации и применения ИИ, для анализа ценного докомпьютерного опыта. Имеется необходимость в применении данных способов, предлагается дальнейшая разработка данного предложения.

FORMALIZATION OF EXPERT PARAMETERS OF A SINGLE PRODUCT

Leonid S. Nikhamkin

LLC "SK-SERVICE"

15, Lenina Str., Perm, Russia, 614068

Leonid1555@yandex.ru

Searching for the causes of hard-to-solve hidden breakdowns of expensive energy-intensive products is one of the actual tasks of modern mechanical engineering. This work can significantly help in the development of products and in the broad adaptation to AI of any objects, by expert formalization of features and application of valuable pre-computer experience. No works on the presented methods have been found in the modern technical literature. The failure of an expensive experimental service unit at a thermal power plant with an electric motor drive was analyzed. A small database (DB) was developed. A set of parameters for research was expertly assigned. Since the product is unique, an expert analysis was performed for each of the more than 20 parameters. The result was confirmed using parameter formalization. The cause of the failure was found. The main goal of the work is to identify the hidden cause of the product's failure. The end result is to eliminate the cause of the product's failure.

Keywords: analysis, formalization, expert, parameters, product, hard-to-solve, breakdown, feature, weight coefficient, logical connection, research, development, production, dimensions, strength, material, expensive, energy-intensive

ПРОГНОЗИРОВАНИЕ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

Третьякова Карина Алексеевна

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
karinatretyackova@yandex.ru

В статье представлено описание разработки нейросетевой модели для прогнозирования почасового потребления электроэнергии. В качестве инструмента моделирования использованы искусственные нейронные сети MLP и LSTM. Система позволяет с высокой точностью предсказывать объемы потребления электроэнергии на ближайшие 8 часов на основе погодных, рыночных и временных факторов. Полученные результаты могут быть применены в целях оперативного управления энергосистемами, оптимизации графиков нагрузки и повышения устойчивости электросетей.

Ключевые слова: искусственные нейронные сети, прогнозирование потребления электроэнергии, MLP, LSTM, временные ряды, энергетика, промышленный регион

Введение. Прогнозирование потребления электроэнергии является важной задачей в сфере энергетики, особенно в условиях растущей нестабильности спроса. Актуальность проблемы усиливается в промышленных регионах с высокой нагрузкой на электросети, где точный краткосрочный прогноз позволяет не только минимизировать издержки, но и избежать перегрузок. В последние годы в задачах прогнозирования успешно применяются искусственные нейронные сети (ИНС), способные учитывать сложные зависимости и извлекать информацию из больших объемов исторических данных [1–3]. В данной работе рассматривается построение нейросетевой модели прогнозирования на основе двух типов архитектур: многослойного перцептрона (MLP) и сети долгой краткосрочной памяти (LSTM). В качестве исходных данных использовались почасовые показатели потребления электроэнергии, погодные условия и рыночные индексы на примере города Екатеринбурга – крупного промышленного центра Уральского региона [4]. Целью исследования является проектирование, обучение и тестирование нейросетевых моделей, способных прогнозировать энергопотребление с высокой точностью. Практическая значимость разработанной системы заключается в ее применимости для энергокомпаний и промышленных предприятий при планировании нагрузки, управлении генерацией и оптимизации закупок на оптовом рынке электроэнергии.

Постановка задачи и формирование DataSet. Для создания нейросетевой системы были выбраны следующие параметры: X1 – дата, X2 – месяц, X3 – год, X4 – час, X5 – тип дня (0 – рабочий, 1 – будний, 2 – предпраздничный), X6 – отопительный сезон (1 – да, 2 – нет), X7 – индекс равновесных цен на покупку электроэнергии (руб./МВт·ч), X8 – индекс равновесных цен на продажу электроэнергии (руб./МВт·ч), X9 – максимальный индекс равновесной цены (руб./МВт·ч), X10 – минимальный индекс равновесной цены (руб./МВт·ч), X11 – частота (Гц),

X12 – температура ($^{\circ}\text{C}$), X13 – скорость ветра (м/с), X14 – направление ветра (румбы), X15 – видимость (км), X16 – облачность (%), X17 – температура точки росы ($^{\circ}\text{C}$), X18 – влажность (%). Выходной параметр D1 – объем потребления электроэнергии (МВт·ч).

Множество примеров собрано вручную с интернет-источников: сайты АТС «Администратор торговой системы» [5] и Open-Meteo, погодные данные для региона Екатеринбург [6]. Перед построением моделей данные были очищены от пропусков, выбросов и дубликатов. Примеры с аномальными значениями были удалены. Однако аномальные значения погодных факторов (в том числе экстремальные температуры, скорости ветра и влажности) преднамеренно не удалялись, поскольку они отражают реальные климатические особенности Уральского региона. Очистка и предобработка выполнялись с помощью инструментов библиотеки pandas в Python. Объем итогового множества составил 17 544 примера, которые были перемешаны и разделены на обучающее, валидирующее и тестовое множества в соотношении 70, 20, 10%.

Разведочный анализ. В настоящем исследовании для анализа использовались почасовые данные за 2023–2024 гг. по потреблению электроэнергии в Уральском регионе, а также погодные и рыночные характеристики. На первом этапе были рассчитаны основные статистические показатели для всех переменных. Полученные результаты позволили установить, что выборка репрезентативна во временном отношении: данные охватывают полный календарный период с равномерным распределением по месяцам и типам дней. Целевая переменная – объем потребления электроэнергии – варьируется от 23 648 до 36 977 МВт·ч с положительной асимметрией распределения. Временной ряд потребления демонстрирует четкую сезонную структуру: пики нагрузки приходятся на зимние месяцы, минимумы – на летние. Суточный цикл потребления также выражен: минимальные значения ночью, пики – утром и в вечерние часы (рис. 1).




Рис. 1. Временной ряд: потребление электроэнергии

Был выполнен анализ влияния календарных факторов. В будние и выходные дни уровень потребления остается сопоставимым (~29 000–29 200 МВт·ч), но предпраздничные дни характеризуются повышенным потреблением (до 30 500 МВт·ч). Существенные отличия также выявлены при сравнении отопительного и неотопительного сезонов: среднее потребление в отопительный период выше примерно на 4 000 МВт·ч. На заключительном этапе EDA был проведен корреляционный анализ количественных переменных. Выявлены сильные положительные корреляции между индексами цен на электроэнергию ($r \approx 0.82$ –1), а также между температурой и точкой росы ($r = 0.90$). Для предотвращения переобучения и уstra-

нения мультиколлинеарности в модель были включены только информативные и слабо скоррелированные переменные.

В итоговый набор факторов, отобранных для построения прогнозной модели, вошли: X1 – дата, X2 – месяц, X3 – год, X4 – час, X5 – тип дня (0 – рабочий, 1 – будний, 2 – предпраздничный), X6 – отопительный сезон (1 – да, 2 – нет), X7 – индекс равновесных цен на покупку электроэнергии (руб./МВт·ч), X11 – частота (Гц), X12 – температура (°C), X13 – скорость ветра (м/с), X14 – направление ветра (румбы), X15 – видимость (км), X16 – облачность (%), X18 – влажность (%).

Таким образом, подготовленное множество данных учитывает как временные, так и метео- и экономические характеристики, влияющие на поведение потребления электроэнергии, и служит прочной основой для построения моделей краткосрочного прогноза.

Проектирование, обучение и тестирование модели MLP. Проектирование, обучение, тестирование нейросети выполнялись с помощью языка программирования Python в Google Collab. В качестве первой архитектуры была реализована модель многослойного перцептрона (MLP) – простая и широко применяемая структура нейросети для задач регрессии. Обучение проводилось в три этапа, с постепенным учетом временной природы данных.

На начальном этапе реализована базовая модель MLP, на вход которой подавались только текущие значения признаков. Отсутствие временного контекста ограничивало способность модели учитывать динамику и взаимосвязи в последовательных наблюдениях, что снижало точность прогноза. Архитектура сети включала три скрытых слоя с 128, 64 и 32 нейронами соответственно, применялись функции активации $\tanh$ и relu , а также механизмы регуляризации: Dropout с коэффициентом 0.1 и BatchNormalization на каждом уровне. Выходной слой имел линейную активацию, подходящую для решения задачи регрессии. Обучение проводилось с использованием оптимизатора Adam, функции потерь MSE и механизма ранней остановки (EarlyStopping) по значению ошибки на валидационной выборке. **Результаты:** RMSE = 1169.21 МВт·ч, MAPE = 3.04%, $R^2 = 0.53$ – качество прогноза оказалось недостаточным.

На втором этапе внедрен метод скользящего окна, при котором каждый входной вектор формировался из данных за последние 24, 36 и 48 часов. Оптимальная ширина окна составляла 36 часов, при которой модель продемонстрировала лучшие значения метрик на тестовой выборке. **Результаты:** RMSE = 846.63 МВт·ч, MAPE = 2.21%, $R^2 = 0.75$. Улучшим метрики оценки качества модели при помощи добавления экспоненциального затухания.

Техника экспоненциального затухания придает больший вес недавним значениям в окне. Это позволило усилить чувствительность модели к текущим изменениям потребления. Лучшие результаты достигнуты при коэффициенте затухания $\lambda = 0.5$, что обеспечило минимальные значения ошибок и максимальный коэффициент детерминации. **Результаты:** RMSE = 772.48 МВт·ч, MAPE = 1.99%, $R^2 = 0.79$.

Таким образом, поэтапное усложнение модели MLP – от базового варианта к использованию временных окон и экспоненциального затухания – позволило существенно повысить ее прогностические характеристики при сохранении уме-

ренной архитектурной сложности. На рисунках 2–4 представлены графики, демонстрирующие разницу между фактическим и прогнозируемым нейросетью множествами. Из изображенных результатов можно сделать вывод об адекватной работе спроектированной нейросети.




Рис. 2. Результат тестирования искусственной нейронной сети




Рис. 3. Результат тестирования искусственной нейронной сети




Рис. 4. Результат тестирования искусственной нейронной сети

Проектирование, обучение и тестирование модели LSTM. В качестве второй модели для краткосрочного прогнозирования потребления электроэнергии была выбрана архитектура LSTM (Long Short-Term Memory). Для обучения модели использовались последовательности фиксированной длины, сформированные с помощью метода скользящего окна. Были протестированы три варианта длины исторического окна: 24, 36 и 48 часов. В каждом случае модель предсказывала значения объема потребления на следующие 8 часов. Архитектура модели включала два последовательно расположенных слоя LSTM (на 30 и 25 нейронов соответственно), за которыми следовал полносвязный слой из 25 нейронов с активацией $\tanh$ и выходной слой на 8 нейронов. Обучение модели показало устойчивую сходимость как по обучающей, так и по валидационной выборке во всех трех конфигурациях. Наилучшие результаты были достигнуты при ширине окна 48 часов. **Результаты:** $RMSE = 742.39 \text{ МВт}\cdot\text{ч}$, $MAPE = 1.92\%$, $R^2 = 0.92$. На рис. 5–7 представлены графики, демонстрирующие разницу между фактическим и прогнозируемым нейросетью множествами. Из отраженных на рисунках результатов можно сделать вывод об адекватной работе спроектированной нейросети.




Рис. 5. Результат тестирования нейронной сети




Рис. 6. Результат тестирования нейронной сети




Рис. 7. Результат тестирования нейронной сети

Заключение. В ходе проведенного исследования разработана нейросетевая система для краткосрочного прогнозирования почасового потребления электроэнергии на примере города Екатеринбурга. В рамках сравнительного анализа показано, что наилучшие результаты достигаются с использованием LSTM-модели. Разработанная система может быть эффективно использована для оперативного управления энергетическими ресурсами, оптимизации графиков нагрузки, а также повышения надежности функционирования энергосетей в условиях высокой нагрузки и изменчивости спроса. Полученные наработки могут быть адаптированы для других регионов и использованы в задачах прогноза в смежных отраслях энергетики.

Библиографический список

1. elib.bsu.by – Электронная библиотека. URL: <https://elib.bsu.by/bitstream/123456789/231626/1/291-294.pdf>
2. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Академия, 2005. 176 с.
3. www.techscience.com – Tech Science. URL: <https://www.techscience.com/cmc/v83n2/60603/html>
4. onlinelibrary.wiley.com – Online Library Wiley. URL: <https://onlinelibrary.wiley.com/doi/10.1155/2021/1502932>
5. atsenergo.ru – АТС (Администратор торговой системы оптового рынка электроэнергии). URL: <https://www.atsenergo.ru/>
6. open-meteo.com – Open-Meteo. Weather Forecast API Documentation. URL: <https://open-meteo.com/en/docs>

FORECASTING ELECTRICITY CONSUMPTION

Tretyakova Karina Alekseevna

HSE University,
38, Studencheskaya Str., Perm, Russia, 614070
karinatretyackova@yandex.ru

The article presents the development of a neural network model for forecasting hourly electricity consumption in an industrial region. Artificial neural networks of the MLP and LSTM types were used as modeling tools. The system enables high-accuracy predictions of electricity consumption for the next 8 hours based on weather, market, and temporal factors. The obtained results can be applied for real-time energy system management, load schedule optimization, and enhancement of power grid resilience.

Keywords: artificial neural networks, electricity consumption forecasting, MLP, LSTM, time series, energy sector, industrial region

УДК 004.8

ВЫЧИСЛИТЕЛЬНЫЕ НЕЙРОСЕТЕВЫЕ МОДЕЛИ ЗРИТЕЛЬНОЙ СИСТЕМЫ В АНАЛИЗЕ И РАСПОЗНАВАНИИ ИЗОБРАЖЕНИЙ

Гладкий Сергей Леонидович

ООО «Випакс-Разработчик»

614000, Россия, г. Пермь, ш. Космонавтов, 111

lrndlrnd@mail.ru

В работе рассмотрены перспективы разработки и применения вычислительных нейросетевых моделей в компьютерном зрении. Вычислительные нейронные сети не требуют создания огромных наборов данных и больших вычислительных мощностей для обучения. Они являются интерпретируемыми моделями и, по сути, являются аналогом слоев биологической зрительной системы, функции которых заложены генетически. Представлены три вычислительные модели: формы, цвета и геометрических характеристик. Приведены примеры применения данных моделей.

Ключевые слова: сверточная нейронная сеть, глубокое обучение, компьютерное зрение, распознавание изображений, нейронная сеть на основе знаний, переносимое обучение, обобщающая способность, катастрофическая забывчивость, объяснимый искусственный интеллект

Введение. Сверточные нейронные сети (СНС) являются основой методов глубокого обучения при создании современных интеллектуальных систем компьютерного зрения [1, 2]. Большинство нейросетевых моделей в компьютерном зрении используют принципы работы зрительной системы человека [3, 4], в частности принцип иерархии и наличие слоев. Данный принцип был заложен в первую сверточную нейросеть – неокогнитрон [4]. Первые удачные нейросетевые модели, примененные в практических задачах, также использовали принципы организации зрительной системы и обучались последовательно, начиная с первых слоев, на которых выделяются примитивные признаки, и заканчивая более абстрактными, дающими сложные признаки для распознавания изображений. С развитием технологий и специализированных быстродействующих вычислительных комплексов, а также благодаря появлению датасетов изображений с огромным количеством данных методики последовательного обучения слоев были заменены сквозным обучением полных моделей.

В настоящей работе рассматриваются вычислительные (программируемые) нейросетевые модели и их применение в задачах анализа и распознавания изображений. Под вычислительной моделью понимается искусственная нейросетевая модель, которая полностью или частично создана без обучения, путем програм-

мирования синапсов нейронов на основе знаний с целью реализации конкретной функциональности каждого блока модели. Этим вычислительные модели отличаются от большинства современных моделей, которые являются обучаемыми.

Актуальность разработки вычислительных моделей компьютерного зрения обусловлена множеством факторов. Во-первых, они не требуют огромного объема данных и затрат на оборудование для обучения. Вместо этого они используют накопленный многолетний опыт и знания специалистов, работающих с обучаемыми нейросетями [5, 6]. Во-вторых, они, по сути, являются моделями типа «белый ящик», поскольку функциональность каждого блока полностью известна, что позволяет проводить анализ причинно-следственных связей для любого результата.

Наиболее важным фактором актуальности использования программируемых моделей в задачах распознавания является открытие таких моделей в зрительных системах разных животных, в том числе высших приматов, а также человека [3, 4]. Известно, что некоторые нейронные связи, по крайней мере в первичных зрительных областях коры, а также в сетчатке, запрограммированы генетически, а не формируются в процессе обучения. Кроме того, показано, что базовые примитивные признаки, которым обучаются первичные отделы зрительной системы, одинаковы у животных одного вида. Данные отделы могут служить аналогом искусственных вычислительных моделей, которые настроены на выделение заранее заданных фиксированных признаков [3, 4].

В работе представлены вычислительные модели формы, цвета и определения геометрических характеристик объектов. Приведены примеры их использования в задачах компьютерного зрения.

Модель формы. Многие исследования функций зрительной системы показывают, что анализ формы и цвета объектов происходит отдельно, а затем, при необходимости, результаты объединяются [4]. Таким образом, для построения модели формы на первом этапе анализа необходимо удалить всю цветовую информацию и сохранить полную информацию о форме. Удаление цветовой информации с сохранением информации о форме может быть выполнено с помощью градиентного представления [7]. Возможны различные представления градиента для усиления в области малых или больших значений в зависимости от цели использования модели. Вычислительная модель формы подробно описана в работе [7]. Также в данной работе представлен пример применения модели формы для решения проблемы цветовой зависимости нейронных сетей [8].

Модель цвета. Цветовосприятие человека является одним из самых сложных феноменов зрительной системы. Например, такой аспект, как константность цвета, до сих пор не получил исчерпывающего объяснения в виде математической модели [4]. Отметим, что целью создания данной модели цвета не является полное моделирование цветового зрения человека. Разработанная вычислительная модель цвета выполняет функцию замены цвета изображения с учетом яркости. Схема разработанной нейронной сети цвета показана на рис. 1.




Рис. 1. Вычислительная нейронная сеть цвета

В модели используется представление изображения в кодировании Lab. Это представление позволяет отделить яркость от цветовой составляющей. Далее часть изображения с определенным цветом может быть заменена на другое значение цвета. При последующем обратном объединении изображения с измененным цветом с исходной яркостью получается реалистичное изображение. Пример применения нейросетевой модели цвета приведен на рис. 2.



Рис. 2. Пример применения вычислительной нейронной сети цвета

Данная нейросетевая модель цвета может быть использована как составной блок в системах компьютерного зрения для решения задач отделения цветовой составляющей от освещенности и задачи предобработки изображений с целью коррекции цвета. Также данная модель может служить инструментом для автоматизации разметки данных сегментации изображений физических процессов.

Модель геометрических характеристик. Одной из возможностей зрительной системы человека является определение расстояния до объектов. Современные RGBD камеры так же позволяют вычислять расстояние до различных точек изображения. Используя данную информацию, называемую картой глубины, возможно вычислять различные геометрические характеристики объектов – реальные размеры, площадь поверхности и т.д. Разработана вычислительная нейросетевая модель, которая позволяет на основе карты глубины вычислять высоту, площадь видимой поверхности и объем объектов, находящихся на горизонтальной плоской поверхности. Модель представлена на рис. 3.

Данная нейросеть определяет высоту подвеса камеры относительно поверхности пола, выделяет объекты, стоящие на данной поверхности в зоне интереса, и определяет их характеристики: максимальную высоту, суммарную площадь и объем. Пример карты глубины и результатов выделения объекта приведен на рис. 4.

Заключение. В работе представлены три вычислительные нейросети. Модель формы позволяет удалить цветовую информацию из изображения, сохраняя при этом полную информацию о форме. Это позволяет обучать цветонезависимые нейронные сети и является приближенной моделью одной из функций сетчатки. Модель цвета реализует разделение цветовой информации и информации об освещенности на основе концепции оппонентных цветов и может быть использована как алгоритм предобработки цветного изображения для последую-

щего анализа. Модель определения геометрических характеристик использует информацию о расстоянии для определения высоты, площади и объема объектов на горизонтальной плоскости.




Рис. 3. Нейросетевая модель геометрических характеристик




Рис. 4. Результат работы нейросетевой модели геометрических характеристик

Разработка вычислительных нейросетевых моделей является актуальной задачей, поскольку данные модели позволяют реализовать вспомогательные блоки для систем компьютерного зрения. Данные модели не требуют обучения и соответственно сбора и разметки огромных наборов данных. Отсутствие необходимости обучения исключает многие проблемы, характерные для обучаемых моделей, например проблему катастрофической забывчивости и проблему обобщения [9]. Вычислительные нейросети являются моделями типа «белый ящик» и реализуют концепцию интерпретируемого (объяснимого) искусственного интеллекта, они могут использоваться в качестве блоков для реализации переносимого обучения и нейросетей на основе знаний [6].

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., Кадури А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2018. 480 с.
3. Хьюбел Д. Глаз, мозг, зрение / пер. с англ. М.: Мир, 1990. 239 с.
4. Маслэнд Р. Как мы видим? Нейробиология зрительного восприятия / пер. с англ. М.: Альпина Паблишер, 2022. 304 с.
5. Гладкий С. Л. Переносимое обучение на основе знаний в компьютерном зрении // Интеллектуальные системы в науке и технике: сб. ст. по материалам Междунар. науч.-практ. конф. (г. Пермь, 12–18 октября 2020 г.) / под ред. Л. Н. Ясницкого. Пермь, 2020. С. 76–86.
6. Гладкий С. Л. Сверточная нейронная сеть на основе знаний для распознавания символов // Интеллектуальные системы в науке и технике: сб. ст. по материалам Междунар. науч.-практ. конф. (г. Пермь, 12–18 октября 2020 г.) / под ред. Л. Н. Ясницкого. Пермь, 2020. С. 412–422.
7. Гладкий С. Л. Устранение цветовой зависимости сверточных нейронных сетей в задачах компьютерного зрения // Интеллектуальные системы в науке и технике: сб. ст. по материалам Девятой всерос. науч.-практ. конф. с междунар. участием (г. Пермь, 17–18 октября 2024 г.) / под ред. Л. Н. Ясницкого. Пермь, 2024. С. 560–569.
8. Гладкий С. Л., Халявин С. Д. Исследование цветовой зависимости сверточных нейронных сетей в задачах компьютерного зрения // Прикладная математика и вопросы управления. 2024. № 1. С. 111–122. DOI 10.15593/2499-9873/2024.1.07
9. Гладкий С. Л. Проблемы нейросетевых моделей в задачах компьютерного зрения и пути развития объяснимого искусственного интеллекта // Интеллектуальные системы в науке и технике: сб. ст. по материалам Девятой всерос. науч.-практ. конф. с междунар. участием (г. Пермь, 17–18 октября 2024 г.) / под ред. Л. Н. Ясницкого. Пермь, 2024. С. 543–547.

COMPUTATIONAL NEURAL MODELS OF VISION SYSTEM FOR IMAGE ANALYSIS AND RECOGNITION

Sergey L. Gladkiy

LLC “VIPAKS-Developer”

111, Kosmonavtov Ave., Perm, Russia, 614000

lrndlrnd@mail.ru

This work examines the prospects for developing and applying computational neural network models in computer vision. Computational neural networks do not require the creation of huge datasets or extensive computing power for training. They are interpretable models and essentially resemble the layers of the biological visual system, whose functions are genetically programmed. Three computational models are presented: shape, color, and geometric characteristics. Examples of their application are provided.

Keywords: convolutional neural network, deep learning, computer vision, image recognition, knowledge based neural network, transfer learning, generalization, catastrophic forgetting, interpretable artificial intelligence

ИСПОЛЬЗОВАНИЕ АДАПТИВНОЙ ПЕРЕДАЧИ МУЛЬТИМЕДИЙНЫХ ДАННЫХ В РАСПРЕДЕЛЕННЫХ СИСТЕМАХ МАШИННОГО ЗРЕНИЯ

Кокоулин Ростислав Андреевич

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский проспект, 29
kokoulinrostislav@yandex.ru

Южаков Александр Анатольевич

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский проспект, 29
uz@at.pstu.ru

Кокоулин Андрей Николаевич

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский проспект, 29
a.n.kokoulin@at.pstu.ru

Нагибин Дмитрий Викторович

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский проспект, 29
Rostkoks228@gmail.com

Данная статья посвящена эффективности адаптивной передачи видеоданных при использовании в распределенных сетях машинного зрения. Для ее измерения было произведено сравнение влияния различных видов сжатия на передачу изображений.

Ключевые слова: адаптивная передача, JPEG2000, JPEG, прогрессивное кодирование, робототехника, машинное зрение

Введение. В современной робототехнике низкоуровневая передача мультимедийных данных (видео, аудио, показания датчиков) играет ключевую роль для обеспечения эффективного взаимодействия роботов с окружающей средой и операторами в режиме реального времени. При передаче данных важным фактором является оптимизация качества мультимедиа. Оптимизация качества мультимедиа в системах передачи данных – это процесс, направленный на достижение баланса между качеством контента и эффективностью использования ресурсов сети. В условиях ограниченной пропускной способности, нестабильных каналов связи и требований к низкой задержке оптимизация качества мультимедиа становится критически важной задачей. С одной стороны, для обеспечения высокой скорости передачи возможно значительное сжатие передаваемых данных, с другой стороны, сжатие может привести к потере важной информации.

Существует множество методов передачи, применение которых зависит от поставленной задачи. Чаще всего используются решения с использованием видеокодеков H.264/AVC, H.265/HEVC или VP9. Все они используют как пространственное, так и временное сжатие (компенсация движения) для значительного

повышения эффективности кодирования. Однако для решения задач робототехники часто используются низкочастотные системы видеонаблюдения, в которых временное сжатие неэффективно. В этом случае видео можно рассматривать как поток отдельных кадров. Поэтому анализ будет проводиться для отдельных кадров, а условия, необходимые для учета при передаче видеоряда, будут учтены в системе ограничений.

Постановка задачи. Для постановки задачи необходимо определить объект исследования, в данном случае – распределенная система машинного зрения. Она имеет систему записи видео с фиксированной частотой смены кадров FR и временем обработки кадра t и канал связи с переменной скоростью передачи данных BR . Данные условия можно представить в виде системы ограничений:

$$QV \rightarrow \max$$

$$\begin{cases} FR = \text{const} \\ t + \frac{PS}{BR} \leq \frac{1}{FR} \end{cases}$$

Из-за того что частоту смены кадров мы считаем фиксированной, оценивание эффективности будет производиться исходя из качества полученного видеопотока. Полученные данные будут сравниваться с исходными по метрике SSIM [1, 2]. Данная метрика была выбрана ввиду ее более глубокого анализа различий между изображениями, чем для остальных метрик.

Сравниваемые форматы. JPEG – широко используемый стандарт сжатия изображений, разработанный для уменьшения размера файлов фотографий и других изображений с минимальной потерей качества [3]. На первом этапе цифровое пространство кадра преобразуется из RGB в YCbCr. На втором шаге кадр разбивается на блоки. На третьем шаге к каждому из блоков применяется дискретное косинусное преобразование. На четвертом шаге происходит квантование коэффициентов. На пятом шаге коэффициенты упорядочиваются с помощью зигзаг-сканирования, что позволяет сгруппировать близкие по значению коэффициенты. На последнем шаге происходит кодирование информации с помощью кодов Хаффмана [4].

Progressive JPEG – это вариант формата JPEG, который позволяет отображать изображение постепенно, начиная с низкого качества и повышая его по мере загрузки файла [5, 6]. Это позволяет адаптировать кадр к текущей скорости передачи данных. При низкой скорости передачи изображение будет получено целиком, хоть и в более низком качестве. В ином случае будет передана лишь часть изображения. Алгоритм кодирования у него аналогичен, но изменен принцип организации данных, чтобы обеспечивать постепенное отображение кадра.

JPEG 2000 – это современный стандарт сжатия изображений, разработанный как усовершенствованная версия классического JPEG [7, 8]. JPEG 2000 использует более сложные алгоритмы сжатия, что позволяет достичь лучшего качества изображения при меньшем размере файла по сравнению с JPEG. В отличие от классического JPEG, который использует дискретное косинусное преобразо-

вание, JPEG 2000 применяет вейвлет-преобразование. Это позволяет более эффективно обрабатывать изображения, особенно те, которые содержат резкие переходы и текстуры. Он также поддерживает постепенную загрузку изображения, начиная с низкого качества и повышая его по мере загрузки. В этом случае формат носит название Progressive JPEG 2000.

Сравнение работы метода в условиях частичной передачи кадра. Для обеспечения неизменной частоты смены кадров необходимо передавать каждый кадр за одинаковое количество времени. Однако при нестабильной скорости передачи данных возможна неполная передача информации о кадре за необходимое время. Такие кадры будут наиболее сильно влиять на общее представление о качестве переданного видеоряда, поэтому оценивание эффективности будет производиться по их качеству. Сравнение будет производиться для стандартов JPEG, Progressive JPEG, Progressive JPEG 2000, использованная метрика – SSIM.



Рис. 1. Изображение, на котором проводилось сравнение кодеков



Рис. 2. Результат частичной загрузки изображения в разных форматах:
a) – Baseline JPEG; b) – Progressive JPEG; c) – Progressive JPEG 2000

Неполная передача кадра будет имитироваться с помощью разделения данных изображения на части с шагом 10%. Изначальное сравнение будет производиться только для первой части, на последующих этапах будет добавляться следующая часть, и объединенное изображение будет вновь сравниваться с исходным.

Исходя из полученных данных при 10-20% загрузке файла изображения Progressive метод превосходит Baseline JPEG на 37,5%, а Progressive JPEG 2000 превосходит его еще на 8%. При 50% загрузке преимущество снижается до 22%, и 3% соответственно. При дальнейшем увеличении процента передачи кадра преимущество будет снижаться до 5% при 90% передаче кадра.




Рис. 3. Результаты сравнения кодеков Baseline JPEG, Progressive JPEG и Progressive JPEG 2000

Заключение. Предложенный метод обеспечивает адаптивную передачу видеоданных по нестабильным каналам связи. Согласно результатам исследования, он позволит передавать непрерывный видеопоток даже в условиях переменной скорости сети. Этот метод улучшит качество систем машинного зрения, имеющих невысокую вычислительную мощность.

Проведенное исследование показало, что стандарты сжатия Progressive JPEG 2000 и Progressive JPEG обеспечивают наилучшее качество переданного изображения при частичной передаче кадра, достигая почти идеального результата уже на 60% переданных данных. Это свойство позволяет использовать Progressive JPEG 2000 и Progressive JPEG при передаче видео в случаях, когда скорость соединения недостаточна для передачи целого кадра за необходимый интервал времени. Данный факт позволяет компенсировать более сложное кодирование и декодирование кадра, необходимое для прогрессивного формата.

Библиографический список

1. Hore A., Ziou D. Image quality metrics: PSNR vs. SSIM // 2010 20th international conference on pattern recognition. IEEE, 2010. С. 2366–2369.
2. Nilsson J., Akenine-Möller T. Understanding ssim // arXiv preprint arXiv:2006.13846. 2020.
3. Ebrahimi F., Chamik M., Winkler S. JPEG vs. JPEG 2000: an objective comparison of image encoding quality // Applications of Digital Image Processing XXVII. SPIE, 2004. Vol. 5558. P. 300–308.
4. Wallace G. K. The JPEG still picture compression standard // Communications of the ACM. 1991. Vol. 34, no. 4. P. 30–44.
5. In J., Shirani S., Kossentini F. JPEG compliant efficient progressive image coding // Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP'98 (Cat. No. 98CH36181). IEEE, 1998. Vol. 5. P. 2633–2636.
6. Kumar S. N., Bharadwaj M. V. V., Subbarayappa S. Performance comparison of jpeg, jpeg xt, jpeg ls, jpeg 2000, jpeg xr, hevc, evc and vvc for images // 2021 6th International Conference for Convergence in Technology (I2CT). IEEE, 2021. P. 1–8.

7. Marcellin M. W. et al. An overview of JPEG-2000 // Proceedings DCC 2000. Data compression conference. IEEE, 2000. P. 523–541.

8. Malik Mohamad K., Deris M. M. Visualization of JPEG metadata // International Visual Informatics Conference. Berlin, Heidelberg: Springer, 2009. P. 543–550.

ADAPTIVE MULTIMEDIA DATA TRANSFER IN DISTRIBUTED MACHINE VISION SYSTEMS

Kokoulin Rostislav Andreevich

Perm National Research Polytechnic University
29, Komsomolsky Prospekt, Perm, Russia, 614990
kokoulinrostislav@yandex.ru

Yuzhakov Aleksandr Anatolyevich

Perm National Research Polytechnic University
29, Komsomolsky Prospekt, Perm, Russia, 614990
uz@at.pstu.ru

Kokoulin Andrey Nikolaevich

Perm National Research Polytechnic University
29, Komsomolsky Prospekt, Perm, Russia, 614990
a.n.kokoulin@at.pstu.ru

Nagibin Dmitry Viktorovich

Perm National Research Polytechnic University
29, Komsomolsky Prospekt, Perm, Russia, 614990
Rostkoks228@gmail.com

This article examines the effectiveness of adaptive video data transmission when used in distributed machine vision networks. To measure this effectiveness, the impact of different compression methods on image transmission was compared. The object of the study is a distributed machine vision system. It has a video recording system with a fixed frame rate (FR) and frame processing time (t) and a communication channel with a variable data rate (BR). Given that we consider the frame rate fixed, performance will be assessed based on the quality of the received video stream. The resulting data will be compared to the original data using the SSIM metric.

Keywords: adaptive transfer, JPEG 2000, JPEG, progressive encoding, robotics, machine vision

ИССЛЕДОВАНИЯ ЗАВИСИМОСТИ ТОЧНОСТИ РАСПОЗНАВАНИЯ ОТ СКОРОСТИ ПРОХОЖДЕНИЯ ЧЕЛОВЕКА ПЕРЕД ВИДЕОКАМЕРОЙ

Федяев Олег Иванович

ФГБОУ ВО «Донецкий национальный технический университет»
283001, Россия, ДНР, г. Донецк, ул. Артема, 58
olegfedyayev@mail.ru

Суханов Антон Алексеевич

ФГБОУ ВО «Донецкий национальный технический университет»
283001, Россия, ДНР, г. Донецк, ул. Артема, 58
studysukhanov@mail.ru

Работа посвящена исследованию зависимости точности распознавания от скорости прохождения человека перед видеокамерой на разных объемах тестируемых датасетов и используемых вычислительных ресурсов. Экспериментальные исследования проводились на системе видеорегистрации присутствия студентов на учебном занятии. Распознавание лиц студентов осуществляется в режиме реального времени с использованием сверточной нейронной сети модели VGGFace16. При моделировании световой поток с изображениями лиц, подаваемый на видеокамеру системы распознавания, генерировался отдельным компьютером, задающим различные варианты вычислительных экспериментов. Получены результаты влияния динамики передачи лиц в видеопоток на точность распознавания.

Ключевые слова: компьютерное зрение, распознавание лиц, видеорегистрация студентов, видеопоток, сверточная нейронная сеть, модель VGGFace16

Введение. В работе рассматривается решение задачи автоматического контроля присутствия студентов в аудитории с помощью компьютерного зрения. На кафедре программной инженерии ДонНТУ ведутся научно-технические работы по применению компьютерного зрения для контроля проведения учебных занятий в режиме реального времени [1]. В настоящее время разработана и тестируется система автоматической регистрации студентов при входе в аудиторию с помощью компьютерного распознавания лица человека на основе сверточной нейронной сети. Основные трудности компьютерного распознавания лиц в реальном времени связаны со скоростью изменения изображений объектов в видеопотоке, положением, размером и ракурсом лица в кадре, освещением и различными видами помех [2].

Поэтому целью данной работы является исследование зависимости точности распознавания от скорости прохождения человека перед видеокамерой при использовании типовых технических и программных средств.

Система видеорегистрации студентов при входе в аудиторию. Автоматический контроль присутствия студентов в аудитории система осуществляет в режиме реального времени благодаря последовательному выполнению следующих функций: локализации лиц на изображении, формирования вектора признаков лиц сверточной нейронной сетью, сравнения распознаваемого лица с эта-

лонами из базы данных и отметке студента в электронном журнале группы. Блок обнаружения лиц принимает изображения с веб-камер, выделяет и локализует на них лица. Каждое выделенное изображение лица передается в блок формирования вектора признаков, который реализует распознавательную функцию.

Для выработки признаков лица применялась сверточная нейронная сеть VGGFace16, которая предварительно была обучена на примерах фотографий 2622 человек (по 1000 фотографий на человека) [3, 4]. Поэтому результатом работы сети является 2622-мерный вектор, каждый элемент которого представляет собой вероятность сходства входного лица с одним лицом из обучающего множества. Тогда два изображения лица будут относиться к одному человеку, если они в одинаковой мере похожи на лица из обучающего множества. Для этого вектора признаков этих изображений в пространстве лиц из обучающего множества должны образовывать между собой достаточно острый угол.

При распознавании в блоке сравнения вектор признаков распознаваемого лица, полученный с выхода сверточной нейронной сети, сравнивается со всеми векторами базы данных. Процедура сравнения основывается на методе вычисления косинусного сходства вектора распознаваемого лица с каждым вектором-эталоном из базы данных.

Распознаваемое лицо считается соответствующим эталону, если полученный коэффициент сходства выше определенного значения (в работе использовалось значение 0.7).

Интерфейс системы распознавания студентов при входе в аудиторию.

Видеорегистрация студентов при входе в аудиторию осуществляется в режиме реального времени (рис. 1). Эффективность распознавания существенно зависит от положения видеокамеры, расстояния от нее до студента и, что особенно важно, от того, с какой скоростью студент проходит перед камерой. Исследованию влияния скорости на качество распознавания будет посвящен последний раздел статьи.



Рис. 1. Распознавание студента при входе в аудиторию

С помощью главного окна системы преподаватель может наблюдать за процессом видеорегистрации и управлять информацией о студентах (рис. 2). 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). Для удобства видеоконтроля цвет строки студента меняется в зави-

симости от его состояния. На рис. 2 показан факт регистрации студента в таблице текущего занятия по учебной дисциплине «Распознавание образов».




Рис. 2. Главное окно преподавателя для управления системой

Исследование зависимости точности распознавания от скорости прохождения человека перед видеокамерой. Для проведения экспериментов, близких к реальным условиям прохождения студентов перед камерой, была построена техническая платформа на базе двух компьютеров. Также была использована база данных лиц, подготовленная лабораторией компьютерного зрения Массачусетского университета [5]. Она содержит цветные фотографии 1680 человек. Каждый человек имеет от 2 до 50 фотографий, сделанных с разным ракурсом.

На первом компьютере была установлена система распознавания студентов с подключенной к нему веб-камерой. Веб-камера, установленная на штатив и зафиксированная в одном положении, была направлена на монитор второго компьютера и располагалась на расстоянии 1 метра от экрана монитора. Технические характеристики веб-камеры: разрешение в pix равно 1280×720 ; тип матрицы – CMOS; фокусное расстояние автоматическое; частота кадров – до 30 кадров/секунду при разрешении в 1280×720 . Технические характеристики системы распознавания: процессор – Intel Core i5-9400F CPU 2.90GHz; оперативная память – 16 ГБ; тип системы – 64-разрядная операционная система, процессор – x64; видеокарта – NVIDIA GeForce RTX 4060 TI; операционная система – Windows.

На втором компьютере (генераторе фотографий) подготовлена презентация Power Point с фотографиями людей, позволяющая формировать световой поток изображений лиц из базы данных распознаваемых людей.

Предварительно система распознавания была обучена на четырех базах данных (датасетах) разного размера: 25, 50, 75 и 100. Входные данные для тестирования системы распознавания поступают с генератора фотографий и представляют собой изображения лиц, авторизованных людей, которые не входили в обу-

чающее множество. Для исследования зависимости точности распознавания от скорости прохождения использована метрика точности Recall [6].

Эксперимент посвящен анализу синхронизации двух независимых и одновременно протекающих динамических процессов, определяемых временем прохождения человека через зону кадра и скоростью распознавания лица, зависящей от вычислительных ресурсов, алгоритма распознавания и размера хранилища лиц. Для обеспечения качественной идентификации лиц с помощью применяемых программно-аппаратных средств распознавания необходимо знать минимальное время задержки лица в кадре, чтобы процесс распознавания успел завершиться. Это важно при распознавании людей в режиме реального времени. Двухкомпьютерная платформа позволяет имитировать динамику прохождения людей перед видеокамерой и оценить точность распознавания получаемого потока лиц нейросетевой системой, реализованной на конкретном физическом процессоре. На рис. 3 представлены исследования влияния скорости прохождения человеком перед камерой на точность распознавания в метрике Recall.

Как можно заметить, уменьшение интервала смены фотографий начиная с 1 секунды приводит к резкому снижению точности распознавания (показатель метрики FN увеличивается). Это происходит из-за «пропуска» некоторых фотографий при маленьких интервалах, потому что система не успевает распознать предыдущую фотографию, так как время распознавания одной фотографии превышает интервал смены светового потока от экрана монитора.




Рис. 3. Зависимость точности распознавания от скорости прохождения человека перед видеокамерой на разных объемах тестируемых датасетов

Таким образом, рассмотренная система распознавания, реализованная на оборудовании с приведенными техническими характеристиками, сможет выполнять распознавание людей в режиме реального времени, если люди перед камерой будут находиться не менее 1 секунды. Это необходимо учитывать при тестировании системы в реальных условиях, т.е. при распознавании студентов при входе в аудиторию.

Заключение. Разработана система видеорегистрации студентов при входе в аудиторию. Изображения лиц поступают с видеокамеры в режиме реального времени. Экспериментальным путем получена оценка зависимости точности рас-

познавания от скорости прохождения человека перед видеокамерой на разных объемах тестируемых датасетов и используемых вычислительных ресурсов. Люди перед камерой должны находиться не менее 1 секунды.

При проведении лекций с большим количеством студентов система автоматизирует учет присутствия студентов в аудитории и накапливает в электронном журнале статистические данные об учебной дисциплине каждого студента в течение семестра. Благодаря компьютерному зрению система устраняет потери времени преподавателя при ручной регистрации присутствия учащихся в аудитории и облегчает ему ведение журнала учета.

Правовые нормы, связанные с видеорегистрацией учащихся, соблюдены путем письменного согласия участников учебного процесса.

Библиографический список

1. Суханов А. А., Федяев О. И. Исследование качества распознавания студентов по изображению лиц в системе видеоконтроля // Информационно-телекоммуникационные системы и технологии: Материалы Всерос. науч.-практ. конф., Кемерово, 23–25 октября 2024 г. Кемерово: Кузбасский гос. техн. ун-т им. Т. Ф. Горбачева, 2024. С. 210–214.
2. Goodfellow Y. Bengio A. Courville: Deep learning. MIT Press, 2016. 802 p.
3. Gulli S. P. Deep Learning with Keras: Implement neural networks with Keras on Theano and TensorFlow. Packt Publishing, 2017. 318 p.
4. Simonyan K., Zisserman A. Computer vision and Pattern Recognition. Very Deep Convolutional Networks for Large-Scale Image Recognition. URL: <https://arxiv.org/abs/1409.1556>
5. Face Recognition Dataset – Oneshot Learning // Kaggle. URL: <https://www.kaggle.com/datasets/stoicstatic/face-recognition-dataset/data>
6. Khawaja Muhammad Fahd. Comparison of Evaluation Metrics used in Machine Learning Models. URL: <https://www.educative.io/blog/evaluation-metrics-ml-models>

A STUDY OF THE DEPENDENCE OF RECOGNITION ACCURACY ON THE SPEED OF A PERSON PASSING BY A VIDEO CAMERA

Oleg I. Fedyaev

Donetsk National Technical University
58, Artema Str., Donetsk, DPR, Russia, 283001
olegfedyayev@mail.ru

Anton A. Sukhanov

Donetsk National Technical University
58, Artema Str., Donetsk, DPR, Russia, 283001
studysukhanov@mail.ru

This work is devoted to studying the dependence of recognition accuracy on the speed of a person passing by a video camera, considering different sizes of testing datasets and the computational resources used. Experimental research was conducted on a video surveillance system for recording student attendance in a classroom. The faces of students are recognized in real-time using the VGGFace16 convolutional neural network model. For modeling purposes, the light stream with facial images fed into the recognition system's video camera was generated by a separate computer, which configured various computational experiment scenarios. The results demonstrate the impact of the dynamics of face transmission in the video stream on recognition accuracy.

Keywords: computer vision, face recognition, student attendance video recording, video stream, convolutional neural network, VGGFace16 model

УДК 004.032.26

МОДЕЛИРОВАНИЕ ТЕЧЕНИЯ В КВАДРАТНОЙ КАВЕРНЕ НА ФИЗИЧЕСКИ ИНФОРМИРОВАННЫХ СЕТЯХ РАДИАЛЬНЫХ БАЗИСНЫХ ФУНКЦИЙ

Горбаченко Владимир Иванович

Пензенский государственный университет
440026, Россия, г. Пенза, ул. Красная, 40
gorvi@mail.ru

Стенькин Дмитрий Александрович

Пензенский государственный университет,
440026, Россия, г. Пенза, ул. Красная, 40
stynukin@mail.ru

Представлены новые алгоритмы моделирования течения в квадратной каверне с помощью физически информированных сетей радиальных базисных функций, для обучения которых адаптирован оптимизатор Sophia. Для реализации сетей разработаны расширения библиотеки TensorFlow, реализующие слои сети радиальных базисных функций, функции потерь и адаптированный алгоритм обучения.

Ключевые слова: дифференциальные уравнения с частными производными, физически информированные сети радиальных базисных функций, гидродинамика, квадратная каверна, уравнения Навье-Стокса, алгоритм Sophia

Введение. В настоящее время для решения краевых задач, описываемых дифференциальными уравнениями в частных производных, набирают популярность глубокие нейронные сети. В процесс обучения таких нейронных сетей встроены математические описания физических законов в форме краевых задач для дифференциальных уравнений в частных производных. Если известно математическое описание процесса, то для обучения сети не требуется сбор экспериментальных данных, что является большой проблемой для обучения моделей машинного обучения с учителем. Обучение physics-informed neural networks (PINN) [1] основано на минимизации невязок на ограниченном множестве пробных точек на основе информации, полученной путем применения физических законов.

PINN находят бессеточное приближенное аналитическое решение краевой задачи, описываемое архитектурой и параметрами нейронной сети. Так как PINN включают математическую модель, то результаты решения проще интерпретировать, чем результаты классических нейронных сетей. При решении прямых краевых задач на решение не накладываются дополнительные условия и не используются обучающие данные, поэтому при обучении не возникает переобучения, так как нет шума в данных.

PINN являются новым направлением и имеют ряд нерешенных проблем. Главными проблемами, сдерживающими практическое применение PINN, является отсутствие быстрых алгоритмов обучения, учитывающих специфику PINN, которые необходимо заново обучать при решении каждой новой задачи, и расширение классов задач, решаемых на PINN.

В большинстве публикаций PINN реализуются с помощью библиотек глубокого обучения TensorFlow и PyTorch, реализующих автоматическое дифференцирование, и используют полносвязные нейронные сети, содержащие умеренное количество скрытых слоев [1, 2]. Для обучения таких сетей используются градиентные итерационные алгоритмы первого порядка, изначально разработанные для решения задач классификации, обычно оптимизатор Adam. Большие перспективы имеет использование физически информированных сетей радиальных базисных функций (PIRBFN) [3]. Такие сети проще, чем полносвязные сети, их легче обучать. Для таких сетей разработаны градиентные алгоритмы обучения второго порядка [3]. Результаты сравнения полносвязных сетей и сетей радиальных базисных функций [4] показывают преимущество сетей радиальных базисных функций.

Выход PIRBFN для точки $\mathbf{x}$ пространства описывается следующим образом:

$$u(\mathbf{x}) = \sum_{m=1}^M w_m \varphi_m(\mathbf{x}; \mathbf{p}_m), \quad (1)$$

где M – количество радиальных базисных функций (RBF), w_m – вес RBF φ_m , $\mathbf{p}_m$ – вектор параметров RBF φ_m .

Решение задач на PIRBFN требует многократного дифференцирования выхода сети, поэтому используем функцию Гаусса в качестве RBF

$$\varphi(\|\mathbf{x} - \mathbf{c}\|, a) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}\|^2}{2a^2}\right),$$

где $\mathbf{c}$ – координаты центра, a – ширина.

Несмотря на наличие градиентного квазиньютоновского алгоритма Левенберга–Марквардта, адаптированного для обучения PIRBFN [3], актуальна разработка менее трудоемких квазиньютоновских алгоритмов, так как алгоритм Левенберга–Марквардта на каждой итерации обучения требует решения системы линейных алгебраических уравнений с порядком, равным количеству пробных точек, которое может быть достаточно большим. В частности, перспективна адаптация для обучения PIRBFN нового квазиньютоновского алгоритма Sophia [5], отличающегося упрощенным вычислением матрицы Гессе и адаптивной скоростью обучения параметров сети.

Для расширения класса задач, решаемых на PIRBFN, перспективна реализация задач гидродинамики, некоторые из которых реализованы на полносвязных PINN [6–8], но не реализованных на PIRBFN. В качестве модельной задачи выбрано моделирование течения в квадратной каверне.

Модельная задача. Течение в квадратной каверне [9, 10] является двумерным стационарным несжимаемым потоком и представляет собой частный случай уравнений Навье–Стокса. Квадратная каверна с движущейся крышкой – классическая модель в вычислительной гидродинамике, которая используется для анализа поведения вязкой жидкости в замкнутой области. Эта простая геометрическая конфигурация порождает сложную вихревую динамику, демонстрирующую фундаментальные взаимодействия между силами инерции и вязкости. Квадратная каверна представляет из себя идеально квадратный резервуар, заполненный жидкостью. Его верхняя граница – «крышка» – приходит в движение с постоянной скоростью в горизонтальном направлении. Это единственное внешнее воздействие. Задача заключается в том, чтобы понять, как этот сдвиг на границе передается вглубь жидкости, инициируя движение во всей остальной, изначально покоящейся области. Формой области является квадрат со стороной L . Ключевой безразмерный параметр, полностью определяющий систему, – число Рейнольдса $Re = (U \cdot L) / \nu$, где U – скорость крышки, L – длина стороны каверны, ν – кинематическая вязкость жидкости. Эта модель является идеализированным представлением множества реальных процессов: от перемешивания жидкостей в химических реакторах и течения в закрытых водоемах до моделирования движения воздуха в вентилируемых помещениях.

Двумерные стационарные уравнения Навье–Стокса для несжимаемой жидкости с постоянной плотностью при отсутствии внешних сил для малых чисел Рейнольдса (модельная задача решалась с числом Рейнольдса, равным 30) описывают установившееся движение жидкости и имеют вид

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} = 0, \quad (2)$$

$$u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} = -\frac{\partial p}{\partial x} + \frac{1}{Re} \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right), \quad (3)$$

$$u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} = -\frac{\partial p}{\partial y} + \frac{1}{Re} \left(\frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} \right) \quad (4)$$

где u – первая компонента скорости, v – вторая компонента скорости, p – давление, Re – число Рейнольдса. Система (2)–(4) содержит две компоненты скорости, так как течение в квадратной каверне является двумерным.

Граничные условия для поля скорости задают постоянную скорость ($y = L$): $u(x, L) = U, v(x, L) = 0$ для верхней стенки и нулевые значения на остальных стенках. Для поля давления задавались условия Неймана $\partial p / \partial n = 0$, где n – нормаль к соответствующей границе.

Решение задачи (2)–(4) производится на PIRBFN. Каждая переменная вычисляется отдельной PIRBFN. Две сети используются для аппроксимации компонент вектора скорости и одна сеть – для аппроксимации давления. Все три сети

связаны общим функционалом ошибки. Функционал ошибки состоит из суммы квадратов невязок. Для упрощения градиента функционала был добавлен множитель $1/2$:

$$\begin{aligned}
I = & \frac{1}{2} \sum_{i=1}^N \left(u_i \frac{\partial u_i}{\partial x} + v_i \frac{\partial u_i}{\partial y} + \frac{\partial p_i}{\partial x} - \frac{1}{\text{Re}} \left(\frac{\partial^2 u_i}{\partial x^2} + \frac{\partial^2 u_i}{\partial y^2} \right) \right)^2 + \frac{\lambda}{2} \sum_{j=1}^K (u_j - u_j^A)^2 + \\
& \frac{1}{2} \sum_{i=1}^N \left(u_i \frac{\partial v_i}{\partial x} + v_i \frac{\partial v_i}{\partial y} + \frac{\partial p_i}{\partial y} - \frac{1}{\text{Re}} \left(\frac{\partial^2 v_i}{\partial x^2} + \frac{\partial^2 v_i}{\partial y^2} \right) \right)^2 + \frac{\lambda}{2} \sum_{j=1}^K (v_j - v_j^A)^2 + \\
& \frac{1}{2} \sum_{i=1}^N \left(\frac{\partial u_i}{\partial x} + \frac{\partial v_i}{\partial y} \right)^2 + \frac{\lambda}{2} \sum_{j=1}^K (p_j - p_j^A)^2.
\end{aligned} \tag{5}$$

С помощью автоматического дифференцирования находятся градиенты функционала ошибок (5) по всем параметрам PIRBFN, которые применяются различными оптимизаторами для обновления параметров сети.

Адаптация оптимизатора Sophia для обучения PIRBFN. Градиентные алгоритмы обучения нейронных сетей можно рассматривать как коррекцию вектора параметров сети на величину антиградиента функционала ошибки с предобусловливателем (preconditioner)

$$\Theta_{k+1} = \Theta_k - \alpha_k \mathbf{P}_k^{-1} \nabla L(\Theta_k),$$

где Θ_k – вектор параметров нейронной сети на шаге обучения k , α_k – скорость обучения, $\nabla L(\Theta_k)$ – градиент функционала ошибки для вектора параметров сети Θ_k , $\mathbf{P}_k$ – матрица предобусловливателя (preconditioning matrix), которая модифицирует направление антиградиента для ускорения сходимости.

Для градиентных алгоритмов второго порядка лучшим предобусловливателем является гессиан (матрица Гессе), используемый в методе Ньютона, который идеально адаптируется к кривизне функционала ошибки и обеспечивает высокую скорость обучения. Но вычисление гессиана слишком затратно для больших моделей и на практике метод Ньютона не применяется. Квазиньютоновские алгоритмы аппроксимируют матрицу Гессе.

В качестве предобусловливателя большой интерес представляет новый алгоритм Sophia (Second-order Clipped Stochastic Optimization – Стохастическая оптимизация второго порядка с обрезанием) [5]. Sophia является методом второго порядка, так как использует аппроксимацию гессиана для расчета шага обновления. Но Sophia использует аппроксимацию только диагонали гессиана, что требует гораздо меньшего числа арифметических операций для аппроксимации, и использует для предобусловливания механизм отсечения (clipping), масштабируя поправку обновления для каждого параметра сети. В результате оптимизатор Sophia применим для больших сетей и работает гораздо быстрее оптимизаторов первого порядка. Оптимизатор Sophia не применялся для PINNs. Авторами статьи оптимизатор Sophia адаптирован для обучения PIRBFN. Адаптация заключается

в настройке не только весов сети, но и параметров RBF, что избавляет от подбора гиперпараметров. Также предложена простая диагональная аппроксимация гессиана. Рассмотрим алгоритм Sophia. На каждом шаге t обучения сети выполняются следующие действия.

Находятся функционал ошибки (функция потерь) $L_t(\Theta_t)$ и вектор градиента функционала ошибки по параметрам сети $\mathbf{g}_t = \nabla L_t(\Theta_t)$, где Θ_t – вектор параметров сети на шаге t , включающий веса сети и параметры RBF.

Для уменьшения шума с сохранением информации о локальной кривизне вычисляется экспоненциальное скользящее среднее (ЕМА) вектора градиента с преимущественным учетом последнего значения градиента:

$$\mathbf{m}_t = \beta_1 \mathbf{m}_{t-1} + (1 - \beta_1) \mathbf{g}_t,$$

где β_1 – гиперпараметр (коэффициент), $\mathbf{m}_0 = 0$.

Через каждые k шагов обучения ($t \bmod k = 1$) выполняется оценка диагонали гессиана. Для минимизации функционала ошибки типа среднеквадратической ошибки (MSE), используемой в PIRBFN, может быть использована оценка Хатчинсона (Hutchinson's estimator) [11], являющаяся универсальным методом оценки диагонали гессиана с помощью стохастической аппроксимации

$$\text{diag}(\mathbf{H}) \approx \mathbf{v} \square \mathbf{H} \mathbf{v},$$

где $\mathbf{H}$ – матрица Гессе функционала ошибки $L(\Theta)$ с элементами $H_{ij} = \frac{\partial^2 L(\Theta)}{\partial \Theta_i \partial \Theta_j}$,

Θ – вектор параметров сети, включающий веса и параметры RBF, $\mathbf{v}^{(m)}$ – случайные векторы, распределенные по многомерному нормальному распределению с нулевым математическим ожиданием и единичной дисперсией или по распределению Радемахера, когда компоненты вектора с равной вероятностью принимают значения ± 1 , $\square$ – поэлементное умножение. Произведение неизвестного гессиана $\mathbf{H}$ и вектора $\mathbf{v}$ реализуется без явного построения гессиана с использованием трюка Перлмуттера (Pearlmutter's trick) [12]: $\mathbf{H} \mathbf{v} = \nabla_{\Theta} (\mathbf{v}^T \cdot \nabla_{\Theta} L(\Theta))$.

Но оценка Хатчинсона сложна, требует большого числа операций. Поэтому в данной работе в качестве аппроксимации диагонали гессиана предлагается вектор, полученный поэлементным умножением вектора градиента функционала ошибки по параметрам сети $\hat{\mathbf{h}}_t = \mathbf{g}_t \square \mathbf{g}_t$. Идея предлагаемой оценки близка к идее оптимизатора RMSProp [13]. Оптимизатор с таким предобусловливателем учитывает локальную кривизну функционала ошибки. В сетях радиальных базисных функций веса и параметры RBF оказывают разное влияние на скорость сходимости к решению. Предлагаемая оценка автоматически балансирует шаги для разнородных параметров. Многие уравнения в частных производных имеют высокочастотные решения. Приближенный предобусловливатель сильнее сглаживает шум в то время, как более точный расчет гессиана может усиливать шум и неустойчивость.

Полученная оценка $\hat{\mathbf{h}}_t$ сглаживается с помощью экспоненциального скользящего среднего

$$\mathbf{h}_t = \beta_2 \mathbf{h}_{t-k} + (1 - \beta_2) \hat{\mathbf{h}}_t.$$

В оптимизаторе Sophia используется ограничение обновлений параметров сети на случай неточных оценок матрицы Гессе. Также ограничение может помочь в контроле неустойчивости из-за невыпуклости функции потерь:

$$\mathbf{d}_t = \text{clip}\left(\frac{\mathbf{m}_t}{\max(\gamma \cdot \mathbf{h}_t, \varepsilon)}, 1\right),$$

где $\text{clip}(d, s) = \max(\min(d, s), -s)$, γ – параметр для контроля, ε – малая константа.

Таким образом, алгоритм Sophia гарантирует стабильность при неточных оценках гессиана и за счет адаптивного шага быстро сходится в выпуклых областях.

Обновление параметров нейронной сети описывается выражением

$$\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}'_t - \eta \mathbf{d}_t$$

где η – скорость обучения.

Экспериментальное исследование. Эксперименты проводились на компьютере с процессором 12th Gen Intel(R) Core (TM) i5-12400F с тактовой частотой 2.50 GHz, объемом оперативной памяти 16 Гб и видеокартой GEFORCE RTX 3060 TI с 8 Гб видеопамяти.

Для моделирования течения в квадратной каверне с помощью PIRBFN адаптированы оптимизаторы первого и второго порядка. При обучении PIRBFN оптимизатором Sophia через каждые 2 шага обучения выполняется оценка диагонали матрицы Гессе. Для оптимизатора Sophia подобраны гиперпараметры: $\beta_1 = 0,96$, $\beta_2 = 0,99$, скорость обучения весов $\eta = 0.1$, скорость обучения ширины $\eta = 0.001$, скорость обучения центров $\eta = 0.0001$, параметр для контроля $\gamma = 0.01$. Для метода Левенберга–Марквардта параметр регуляризации $\mu = 20$. Было задано 64 RBF и 64 центра RBF на квадратной сетке 8×8 . Ширина и веса RBF инициализированы значениями, близкими к нулю. Подобрано оптимальное количество RBF и пробных точек коллокации: 100 точек внутри области решения и 40 точек коллокации на границе области решения. Для реализации PIRBFN разработаны расширения библиотеки TensorFlow, реализующие слои сети радиальных базисных функций, функции потерь и адаптированных оптимизаторов.

Результаты моделирования показаны на рис. 1.

Результаты сравнения различных методов обучения PIRBFN для моделирования течения в квадратной каверне представлены в табл. 1.

Полученные результаты свидетельствуют о том, что оптимизатор Левенберга–Марквардта позволяет достичь более высокой точности за меньшее число итераций. Оптимизатор Sophia требует значительно большего числа итераций,

чем метод Левенберга–Марквардта. Но за счет исключения решения системы линейных алгебраических уравнений на каждой итерации время вычислений увеличилось несущественно.




Рис. 1. Результаты моделирования: а) – векторное поле скорости; б) – поле давления

Таблица 1

Сравнение алгоритмов обучения PIRBFN

Алгоритм	Достигнутая средняя квадратическая погрешность	Число итераций	Время вычислений, С
Метод градиентного спуска	0.001	5300	750
Метод Нестерова	0.0001	5800	810
Метод ADAM	0.0001	5700	785
Метод Sophia	0.0001	1540	95
Метод Левенберга–Марквардта	0.0001	310	75

Заключение. Разработаны PIRBFN для моделирования течения в квадратной каверне. Для реализации сетей разработаны расширения библиотеки Tensor Flow, реализующие слои сети радиальных базисных функций, функции потерь и адаптированный алгоритм обучения. Для обучения PIRBFN адаптирован оптимизатор Sophia, который позволяет достичь лучшей точности по сравнению с алгоритмами первого порядка и несущественно увеличивает время обучения по сравнению с оптимизатором Левенберга–Марквардта.

Библиографический список

1. Raissi M., Perdikaris P., Karniadakisa G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. 2019. Vol. 378. P. 686–707. DOI 10.1016/j.jcp.2018.10.045
2. Ren Z., Zhou S., Liu D., Liu Q. Networks: Physics-Informed Neural Networks: A Review of Methodological Evolution, Theoretical Foundations, and Interdisciplinary Frontiers Toward Next-Generation Scientific Computing // Applied Sciences. 2025. Vol. 15, no. 14. Article 8092. DOI 10.3390/app15148092
3. Gorbachenko V. I., Stenkin D. A. Mathematical Modeling on a Physics-Informed Radial Basis Function Network // Mathematics. 2024. Vol. 12, no. 2. Article 241. DOI 10.3390/math12020241
4. Gorbachenko V. I., Stenkin D. A., Alqezweeni M. M., Glumskov R. A. Solving Partial Differential Equations on Radial Basis Functions Networks and on Fully Connected Deep Neural Networks // Proceedings

of the International Conference on Intelligent Vision and Computing (ICIVC 2021). ICIVC 2021. Proceedings in Adaptation, Learning and Optimization. Cham: Springer, 2022. Vol. 15. P. 240–249. DOI 10.1007/978-3-030-97196-0_20

5. Liu H., Li Z., Hall D., Liang P., Ma T. Sophia: A Scalable Stochastic Second-order Optimizer for Language Model Pre-training. URL: <https://arxiv.org/abs/2305.14342>

6. McDaniel D., Hu B. Applying Physics-Informed Neural Networks to Solve Navier–Stokes Equations for Laminar Flow around a Particle // Mathematical and Computational Applications. 2023. Vol. 28, no. 5. Article 102. DOI 10.3390/mca28050102

7. Farkane A., Ghogho M., Oudani M., Boutayeb M. Enhancing physics informed neural networks for solving Navier–Stokes equations // International Journal for Numerical Methods in Fluids. 2024. Vol. 96, no. 4. P. 381–396. DOI 10.1002/flid.5250

8. Strizhak S. V., Koshelev K. B. The use of a physically based neural network on the example of modeling hydrodynamic processes that allow an analytical solution // Proceedings of the Institute of System Programming of the Russian Academy of Sciences. 2023. Vol. 35, no. 5. P. 245–258. DOI 10.15514/ISPRAS-2022-35(5)-16

9. Ghia U., Ghia K. N., Shin C. T. High-Re solutions for incompressible flow using the Navier-Stokes equations and a multigrid method // Journal of Computational Physics. 1982. Vol. 48, no. 3. P. 387–411.

10. Botella O., Peyret R. Benchmark spectral results on the lid-driven cavity flow // Computers & Fluids. 1998. Vol. 27, no. 4. P. 421–433.

11. Hutchinson M. F. A stochastic estimator of the trace of the influence matrix for laplacian smoothing splines // Communications in Statistics-Simulation and Computation. 1990. Vol. 19, no. 2. P. 433–450. DOI 10.1080/03610919008812866

12. Pearlmutter B. Fast Exact Multiplication by the Hessian // Neural Computation. 1994. Vol. 6, no. 1. P. 147–160. DOI 10.1162/neco.1994.6.1.147

13. Бишоп К. М., Бишоп Х. Глубокое обучение: принципы и концепции. М.: ДМК Пресс, 2025. 740 с.

MODELING OF FLOW IN A SQUARE CAVITY ON PHYSICS- INFORMED RADIAL BASIS FUNCTION NETWORKS

Gorbachenko Vladimir Ivanovich

Penza State University
40, Krasnaya Str., Penza, Russia, 440026
gorvi@mail.ru

Stenkin Dmitry Aleksandrovich

Penza State University
40, Krasnaya Str., Penza, Russia, 440026
stynukin@mail.ru

New algorithms for modeling flow in a square cavern using physics-informed radial basis function networks are presented, for which the Sophia optimizer has been adapted for training. To implement the networks, extensions to the TensorFlow library have been developed that implement radial basis function network layers, loss functions, and an adapted training algorithm.

Keywords: partial differential equations, physics-informed radial basis function networks, hydrodynamics, square cavern, Navier-Stokes equations, Sophia algorithm

МЕТОД И ДЕМОНСТРАТОР СТАБИЛИЗАЦИИ ОБРАТНОГО МАЯТНИКА С ПРИМЕНЕНИЕМ СПАЙКОВОЙ НЕЙРОСЕТИ

Сергеев Владимир Алексеевич

АО «НИИ молекулярной электроники»

124460, Россия, г. Москва, г. Зеленоград, ул. Академика Валиева, д. 6, стр. 1

sergeev.va@phystech.edu

Тельминов Олег Александрович

АО «НИИ молекулярной электроники»

124460, Россия, г. Москва, г. Зеленоград, ул. Академика Валиева, д. 6, стр. 1

otelminov@niime.ru

В работе предложен новый способ решения задачи стабилизации обратного маятника с использованием спайковых (SNN) нейронных сетей. Разработан демонстратор на основе гироскутера и выполнено сравнение предложенного метода с решением на традиционных (ANN) нейронных сетях. Исследование включает моделирование динамики системы, обучение агентов с подкреплением на основе ANN и их последующую конвертацию в SNN, а также прямое обучение SNN. Основными критериями сравнения являются качество управления, вычислительная сложность и энергоэффективность. Показано, что SNN демонстрируют сопоставимое с ANN качество управления при существенно более низкой оценке энергопотребления, что делает их перспективной технологией для embedded-систем и робототехники.

Введение. Задача стабилизации обратного маятника является классической проблемой в теории управления и робототехнике. Современные подходы с использованием глубокого обучения с подкреплением (DRL) отлично справляются с такой задачей, однако традиционные искусственные нейронные сети (ANN), лежащие в основе DRL-агентов, требуют значительных вычислительных ресурсов и энергозатрат, что затрудняет их развертывание на автономных мобильных устройствах с ограниченной энергоемкостью [1].

Постановка задачи. Для решения задачи была построена модель обратного маятника на движущейся тележке с применением физического движка Unity. Агент DRL был обучен на основе многослойного перцептрона (ANN) с использованием алгоритма PPO [2]. Также был реализован агент на основе SNN с использованием метода конвертации обученной ANN [3] и метода прямого обучения [4]. Для оценки качества работы нейросети оценивалось время стабилизации тележки, устойчивость к внешним возмущениям и энергоэффективность.

Проектирование, обучение и тестирование нейросетей. Обучение ANN производилось с использованием библиотеки TensorFlow с помощью гибридного метода: Behavior cloning с последующим дообучением алгоритмом PPO. Моделирование SNN проводилось с помощью библиотеки Brian2 [5].

Для последующего использования модели на реальных устройствах при обучении были учтены следующие детали:

- разрешающая способность гироскопа и сонара;
- дискретность выходного напряжения от драйверов моторов;
- добавлен шум и случайные скачки показаний датчиков;
- учтена задержка реакции контроллера;
- обучение езде проводилось на случайно сгенерированной поверхности с периодическим приложением случайных сил (толчков).

Тестирование качества управления выполнялась по финальным счетам (scores), тогда как оценка потребления энергии производилась через подсчет количества синаптических операций (ACs) для SNN и операций с плавающей точкой (FLOPs) для ANN. Выигрыш по энергии в симуляции составил почти 2 порядка. Тесты на реальном устройстве показали схожие результаты.

Заключение. Проведенное исследование подтвердило перспективность применения спайковых нейронных сетей (SNN) в робототехнике. Экспериментально показано, что SNN способны достигать качества управления, сопоставимого с традиционными ANN-агентами, обученными по алгоритму PPO. Ключевым результатом работы является демонстрация существенно более высокой энергоэффективности SNN-решений. Это преимущество обусловлено их фундаментальной особенностью – редкой импульсной активностью (спайковыми последовательностями), которая приводит к резкому снижению вычислительной нагрузки по сравнению с ANN. Таким образом, SNN представляют собой оптимальный выбор для развертывания интеллектуальных агентов управления на автономных мобильных платформах со строго ограниченными энергетическими ресурсами.

В будущем планируется аппаратная верификация на нейроморфных процессорах на различных компонентах и исследование возможности обучения на борту для быстрой адаптации к внешним условиям и износу механизмов.

Библиографический список

1. Красников Г. Я., Горнев Е. С., Матюшкин И. В. Общая теория технологий и микроэлектроника. М.: Техносфера, 2020. 434 с. ISBN 978-5-94836-611-1.
2. Schulman J., Wolski F., Dhariwal P. et al. Proximal Policy Optimization Algorithms // arXiv preprint arXiv:1707.06347. 2017.
3. Tang G., Kumar N., Yoo R. et al. Deep Reinforcement Learning with Population-Coded Spiking Neural Network for Continuous Control // Proceedings of the 2020 Conference on Robot Learning. 2020. P. 2016–2029.
4. Diehl P. U., Neil D., Binas J. et al. Fast-classifying, high-accuracy spiking deep networks through weight and threshold balancing // 2015 International Joint Conference on Neural Networks (IJCNN). 2015. P. 1–8. DOI 10.1109/IJCNN.2015.7280696
5. Stimberg M., Brette R., Goodman D. F. Brian 2, an intuitive and efficient neural simulator // eLife. 2019. Vol. 8. e47314. DOI 10.7554/eLife.47314.

METHOD AND DEMONSTRATOR OF INVERSE PENDULUM STABILIZATION USING A SPIKING NEURAL NETWORK

Sergeev Vladimir Alekseevich

JSC “Research Institute of Molecular Electronics”
Bldg 1, 6, Academician Valiev Str., Zelenograd, Moscow, Russia, 124460
vkobelev@niime.ru

Telminov Oleg Aleksandrovich

JSC “Research Institute of Molecular Electronics”
Bldg 1, 6, Academician Valiev Str., Zelenograd, Moscow, Russia, 124460
otelminov@niime.ru

This paper compares the performance of artificial neural networks (ANN) and spiking neural networks (SNN) for solving the inverted pendulum stabilization problem, which is fundamental to hoverboard control. The study includes modeling the system dynamics, training reinforcement agents based on ANNs and their subsequent conversion to SNNs, and directly training the SNNs. The main comparison criteria are control quality, computational complexity, and energy efficiency. It is shown that SNNs demonstrate comparable control quality to ANNs with significantly lower energy consumption, making them a promising technology for embedded systems and robotics.

РАЗРАБОТКА ПРОГРАММНОГО СРЕДСТВА ДЛЯ ИСПОЛЬЗОВАНИЯ МАШИННОГО ОБУЧЕНИЯ И АВТОЭНКОДЕРОВ В ЗАДАЧЕ ФИЛЬТРАЦИИ СИГНАЛА В МАСС-СПЕКТРОМЕТРИИ

Кулик Сергей Дмитриевич

Национальный исследовательский ядерный университет НИЯУ МИФИ
115409, Россия, г. Москва, Каширское шоссе, 31
sedmik@mail.ru

Ахметов Азат Фаридович

Национальный исследовательский ядерный университет НИЯУ МИФИ
115409, Россия, г. Москва, Каширское шоссе, 31
azat.akhmetov.1998@bk.ru

В работе рассматривается применение методов машинного обучения, в частности автоэнкодеров, для задачи фильтрации сигналов в масс-спектрометрии. Традиционные алгоритмы обработки спектральных данных, основанные на статистических моделях и фильтрах, зачастую ограничены в эффективности при наличии шумов сложной структуры и низком соотношении сигнал / шум. Использование автоэнкодеров позволяет обучать модели, способные выделять информативные компоненты спектра и подавлять шумовые артефакты без необходимости явного задания параметров фильтрации. В статье обсуждаются архитектурные особенности нейронных сетей, подходы к обучению на реальных и синтетических данных, а также проводится сравнение предложенного метода с классическими техниками предобработки сигналов. Экспериментальные результаты показывают, что применение автоэнкодеров обеспечивает более высокое качество восстановления спектров и улучшает точность последующего анализа масс-спектрометрических данных.

Ключевые слова: нейросетевые технологии, фильтрация данных, спектры, автоэнкодеры

Введение. Фильтрация сигналов является ключевым этапом предобработки данных в масс-спектрометрии, поскольку качество дальнейшего анализа напрямую зависит от степени подавления шумов и сохранения информативных характеристик спектра. Существующие методы фильтрации можно условно разделить на два класса: подходы model-based и data-driven [1].

Методы model-based основываются на предположениях о природе сигнала и шума. Классическими примерами являются линейные и нелинейные фильтры, вейвлет-преобразования, а также статистические модели, позволяющие аппроксимировать спектр и отделять полезный сигнал от шумовой компоненты. Преимуществом таких подходов является их интерпретируемость и относительная простота реализации. Однако их эффективность существенно снижается в случаях, когда реальные шумы обладают сложной структурой или не соответствуют заложенным предположениям.

В противоположность этому методы data-driven используют обучающиеся алгоритмы, способные автоматически выявлять закономерности в данных без

строгого задания модели шума. Машинное обучение, в особенности глубокие нейронные сети, предоставляет инструменты для построения нелинейных фильтров, адаптирующихся к особенностям конкретного набора спектров. Среди таких подходов особый интерес представляют автоэнкодеры, которые могут обучаться реконструировать сигнал, выделяя его ключевые структуры и одновременно подавляя шум.

Таким образом, интеграция методов data-driven в задачи фильтрации сигналов открывает перспективы для повышения точности и устойчивости анализа масс-спектрометрических данных по сравнению с традиционными model-based подходами.

Постановка задачи и формирование DataSet. Для создания нейросетевой системы были собраны данные [2] из открытых источников, исследованы возможные функции активации и функции потерь, а также архитектуры автоэнкодеров. Данные нормализованы и приведены к единообразному шаблону csv-файлов.

Задача фильтрации сигналов, представляющих собой зависимость интенсивности некоторой физической величины от времени, является ключевым этапом анализа экспериментальных данных. В условиях шумовых искажений особую актуальность приобретает использование методов машинного обучения, в частности вариационного автоэнкодера (VAE).

VAE сочетает вероятностное моделирование с глубокими [3] нейронными сетями: кодировщик отображает входные данные в распределение в скрытом пространстве, а декодировщик восстанавливает сигнал из этого распределения. Для эффективной работы модели важен выбор функции активации на выходном слое и функции ошибки (loss function), которые должны соответствовать предполагаемому закону распределения шума.

Проектирование, обучение и тестирование нейросети. Рассмотрим три случая: нормальный, пуассоновский и равномерный шумы – и подходящие для них комбинации активаций и функций потерь.

1. Случай нормального (гауссовского) шума. Нормальный шум возникает в результате суммирования большого числа независимых случайных факторов. Он широко распространен в физических измерениях: электронные флуктуации [4] в датчиках, тепловой шум, ошибки усилителей и аналоговых трактов. Гауссовское распределение хорошо описывает такие процессы, а дисперсия шума отражает интенсивность случайных искажений.

Для гауссовского шума оптимально использовать линейную активацию (identity function) на выходе декодера. Это связано с тем, что сигналы могут принимать любые действительные значения, а линейный выход [5] не накладывает ограничений на диапазон предсказаний. Здесь естественным выбором является Mean Squared Error (MSE), эквивалентная минимизации отрицательного логарифма плотности нормального распределения. MSE учитывает квадратичные отклонения и «штрафует» за большие ошибки сильнее, чем за малые.

Такой подход обеспечивает сглаживание случайных колебаний и восстанавливает плавную форму сигнала. Однако MSE чувствителен к выбросам: если в данных присутствуют редкие, но большие артефакты, они будут доминировать

в функции ошибки. Тем не менее для большинства экспериментов с нормальным шумом комбинация [6] «линейная активация + MSE» является стандартом.

2. Случай пуассоновского шума. Пуассоновский шум характерен для счетных процессов, когда регистрируется количество частиц, фотонов или событий за фиксированный интервал времени. В отличие от гауссовского шума, здесь дисперсия равна математическому ожиданию. Это означает, что чем выше интенсивность сигнала, тем больше разброс наблюдаемых значений. В масс-спектрометрии это особенно актуально: интенсивность пиков отражает число зарегистрированных ионов. Для моделирования счетных данных требуется обеспечить неотрицательность выходов декодера. Наиболее подходящие функции активации – softplus или экспонента. Softplus предпочтительнее, так как она обеспечивает устойчивый рост при больших значениях, избегая чрезмерной экспоненциальной чувствительности. Используется Poisson Negative Log-Likelihood (Poisson NLL).

Такой выбор позволяет автоэнкодеру учитывать статистическую природу данных: шум трактуется не как «помеха», а как следствие дискретного характера регистрации. Модель [7] учится выделять истинный сигнал в условиях, когда разброс увеличивается с ростом интенсивности. Это особенно полезно для восстановления спектров, где сохранение амплитуд пиков имеет решающее значение. Ограничение в том, что при низких значениях интенсивности предсказания могут быть менее стабильными, так как дискретный шум доминирует.

3. Случай равномерного шума. Равномерный шум описывает ситуацию, когда искажения распределены равномерно в пределах фиксированного диапазона $[-a, a]$. Такой шум может возникать при квантовании аналоговых сигналов, в системах с ограниченной разрядностью, а также при некоторых видах систематических колебаний приборов. В отличие от нормального шума, равномерный шум не имеет «хвостов» и характеризуется одинаковой вероятностью малых и больших отклонений.

Для работы с равномерным шумом целесообразно использовать $\tanh$ (если данные нормированы в диапазон $[-1, 1]$) или sigmoid (если диапазон $[0, 1]$). Такие активации отражают ограниченность возможных значений интенсивности и стабилизируют работу сети, предотвращая выход предсказаний за физически допустимые пределы.

Наиболее подходящая функция ошибки – Mean Absolute Error (MAE): MAE соответствует минимизации L1-нормы и хорошо согласуется с равномерным распределением ошибок, где вероятность отклонений одинакова во всем диапазоне.

Использование MAE делает модель менее чувствительной к выбросам и позволяет автоэнкодеру [8] эффективно выделять устойчивую структуру сигнала, не усредняя равномерный шум. Такой подход особенно полезен в случаях, когда данные подвержены систематическим искажениям фиксированной амплитуды. Ограничением является то, что MAE менее чувствителен к мелким колебаниям сигнала и может приводить к более грубому приближению по сравнению с MSE.

Результаты. По итогам экспериментов была получена таблица значений PSNR.

Значения PSNR, полученные в ходе эксперимента

Функция ошибки	Значение PSNR
MSE	–1.3
Poisson NLL	23.4
MAE	5.4

Из таблицы видно, что исходя из специфики данных масс-спектрометрии имеет смысл использовать функцию ошибки Poisson NLL, поскольку автоэнкодер, обученный [9], с такой функцией дает наибольшее значение PSNR при решении задачи фильтрации [10].

Заключение. В результате исследования построена система нейросетевого фильтра для данных масс-спектрометрии. Выбор активации и функции ошибки в вариационном автоэнкодере должен быть согласован с природой шума. Для нормального шума естественны линейный выход и MSE; для пуассоновского – softplus и Poisson NLL; для равномерного – ограничивающая активация (tanh / sigmoid) и MAE. Такой адаптивный выбор делает фильтрацию сигналов более точной и позволяет сохранить информативные характеристики данных даже при сильных искажениях.

Библиографический список

1. Саммерфилд М. Программирование на Python 3. Подробное руководство. М.: Литрес, 2009. 607 с.
2. Kaggle. Система организации конкурсов по исследованию данных, а также социальная сеть специалистов по обработке данных и машинному обучению. URL: <https://www.kaggle.com> (дата обращения: 12.05.2024).
3. Ахметов А. Ф. Разработка программного средства для генерирования изображений с использованием генеративных нейронных сетей: отчет о НИР (рукопись) / рук.: С. Д. Кулик. М.: НИЯУ МИФИ, 2024. 33 с.
4. Солем Я. Э. Программирование компьютерного зрения на языке Python. М.: ДМК Пресс, 2016. 312 с.
5. Клетте Р. Компьютерное зрение. Теория и алгоритмы. М.: ДМК Пресс, 2014. 325 с.
6. Любанович Б. Простой Python. Современный стиль программирования. 2-е изд. СПб.: Питер, 2021. 592 с.
7. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: ДМК Пресс, 2005. 231 с.
8. Чорбаа Н. А., Ле Ань Ту, Толстой И. М. Сравнительный анализ методов детектирования объектов на радиолокационных изображениях при помощи нейронных сетей // Научный результат. Информационные технологии. 2020. Т. 5, № 4. С. 15–25. DOI [10.18413/2518-1092-2020-5-4-0-3](https://doi.org/10.18413/2518-1092-2020-5-4-0-3). EDN [XOATUM](https://www.edn.ru/10.18413/2518-1092-2020-5-4-0-3)
9. Зинченко А. П. Разработка прототипа программного средства для сбора и хранения данных специального нейрокомпьютерного интерфейса на основе TGAM1, Arduino UNO и сухих электродов: отчет о НИР (рукопись) / рук.: С. Д. Кулик. М.: НИЯУ МИФИ, 2024. 30 с.
10. Цулейскири Е. Г. Применение нейрокомпьютерных интерфейсов для реабилитации и улучшения условий жизни пациентов с нарушениями моторных функций нервной системы // Инновационные технологии в науке и образовании (Конференция «ИТНО 2022»): сб. науч. тр. X Юбилейной междунар. науч.-практ. конф., с. Дивноморское, 26 сентября – 02 октября 2022 г. / редкол.: Ю. Ф. Лачуга и др. Ростов-на-Дону: ДГТУ-ПРИНТ, 2022. С. 203–206. DOI [10.23947/itse.2022.203-206](https://doi.org/10.23947/itse.2022.203-206). EDN [PJDMKX](https://www.edn.ru/10.23947/itse.2022.203-206)

DEVELOPMENT OF A SOFTWARE TOOL FOR USING MACHINE LEARNING AND AUTOENCODERS IN THE TASK OF SIGNAL FILTERING IN MASS SPECTROMETRY

Kulik Sergey Dmitrievich

National Research Nuclear University MEPhI
31, Kashirskoye Highway, Moscow, Russia, 115409
sedmik@mail.ru

Akhmetov Azat Faridovich

National Research Nuclear University MEPhI
31, Kashirskoye Highway, Moscow, Russia, 115409
azat.akhmetov.1998@bk.ru

The paper considers the application of machine learning methods, in particular autoencoders, for the task of filtering signals in mass spectrometry. Traditional spectral data processing algorithms based on statistical models and filters are often limited in efficiency in the presence of complex structure noise and low signal-to-noise ratio. The use of autoencoders makes it possible to train models capable of isolating informative components of the spectrum and suppressing noise artifacts without the need to explicitly set filtering parameters. The article discusses the architectural features of neural networks, approaches to learning from real and synthetic data, and compares the proposed method with classical signal preprocessing techniques. Experimental results show that the use of autoencoders provides a higher quality of spectrum reconstruction and improves the accuracy of subsequent analysis of mass spectrometric data.

Keywords: neural network technologies, data filtering, spectra, autoencoders

УДК 004.021:004.8

АНАЛИЗ ПРИМЕНЕНИЯ АЛГОРИТМОВ СОГЛАСОВАНИЯ ДЛЯ УПРАВЛЕНИЯ РОЕМ АВТОНОМНЫХ АГЕНТОВ

Шаронов Никита Сергеевич

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
69224@pspu.ru

Повышенный спрос на методы управления роями автономных агентов, например мобильными роботами и автономными транспортными системами, обуславливает актуальность алгоритмов согласования. Алгоритмы такого рода обеспечивают децентрализованное управление роем. Настоящее исследование посвящено анализу базовых алгоритмов согласования, а также изучению применимости к практическим сценариям, таким как навигация роя и кооперативное достижение цели. Особое внимание уделяется проблемам реализации в реальных условиях и влиянию топологии сети на сходимость и устойчивость. В исследовании подчеркивается практический потенциал алгоритмов согласования для управления роем и необходимость прикладных исследований в условиях реальной среды.

Ключевые слова: алгоритмы, алгоритмы согласования, мультиагентная система, рой, искусственный интеллект

Введение. В настоящее время наблюдается экспоненциальный рост интереса к технологиям управления роями автономных агентов: мобильных роботов, автономных транспортных средств. Согласно исследованию Mordor Intelligence, мировой рынок автономных агентов демонстрирует среднегодовой темп роста более 50% в период с 2021 по 2026 г. [1] Усиливается внимание со стороны производственной индустрии и академических кругов к системам управления множеством автономных единиц и проблеме их согласования.

Алгоритмы согласования являются ключевым основанием для децентрализованного управления роем автономных агентов. Они обеспечивают агентам, взаимодействующим только с соседями в заданной коммуникационной сети, с течением времени приходиться к согласованному значению некоторой переменной. Эти алгоритмы изучены в теории графов, теории управления, распределенных вычислений; обеспечивают формальные гарантии сходимости, устойчивости к шуму, задержкам передачи, разрывам связности. В контексте автономных агентов алгоритмы дают архитектуру, не требующую центрального узла управления.

Главной целью исследования выступает анализ актуальных подходов и возможности применения алгоритмов согласования при управлении роем автономных агентов для сопоставления спектра практических задач и оптимальных с точки зрения производительности алгоритмов. Задачи работы включают классификацию алгоритмов согласования применительно к робототехническим роям, оценку кри-

териев эффективности (скорости сходимости, устойчивости при нарушениях связи, вычислительной и коммуникационной нагрузки), исследование влияния топологии взаимодействий между агентами; представление практических примеров применения, а также выявление открытых проблем и направлений дальнейших исследований.

Основы алгоритмов согласования. Алгоритм согласования – это распределенный алгоритм, при котором множество агентов (узлов), взаимодействуя только с локальными соседями через канал связи, с течением времени приходят к общему (согласованному) значению некоторой переменной состояния. Иллюстрация достижения общего состояния представлена на рис. 1 и достижима в результате итерации алгоритма среднего согласования. При этом не требуется центрального управляющего узла, а взаимодействие реализуется на основе обмена информацией между агентами. Достаточно точным для изложения идеи исследования послужило сравнение монолитной и микросервисной архитектуры в паттернах проектирования информационных систем [5].




Рис. 1. Достижение согласованного состояния агентов

Обеспечение сходимости не является достаточно объективным параметром оценки качества алгоритма. Для придания точности оценки необходимо ввести дополнительные критерии. С этой целью существует четыре главных параметра, важных для оценки и проектировании алгоритмов согласования.

1. Сходимость – свойство, означающее, что состояния всех агентов асимптотически стремятся к одному общему значению или к допустимому диапазону отклонений.

2. Устойчивость – критерий алгоритма сохранять свою корректность и свойства в условиях возмущений.

3. Задержки в коммуникации (как постоянные, так и переменные), а также наличие потерь сообщений или асинхронных обновлений могут влиять на корректность или скорость сходимости. В исследованиях рассматриваются и теоретические результаты, обеспечивающие сходимость при таких ограничениях [2].

4. Масштабируемость – способность алгоритма работать при увеличении числа агентов, изменении плотности или диаметра сети, возможно, при динамических изменениях топологии.

В рамках настоящей работы рассмотрим также три основных алгоритма на примерах [6] (табл. 1).

Таблица 1

Основные алгоритмы согласования

Название	Описание	Пример
Среднее согласование (Average consensus)	Каждый агент обновляет свое состояние как взвешенное среднее состояний своих соседей и себя	Выравнивание скорости и направления у косяков рыб. Каждый агент корректирует свое движение относительно ближайших соседей, стремясь минимизировать различия. В итоге вся группа движется согласованно
Алгоритмы лидер-ведомые (Leader-follower / leader-based consensus)	Избранные агенты являются лидерами, которые задают целевое состояние (например, позицию, траекторию), а ведомые агенты стремятся согласовать свои состояния с состоянием лидеров посредством взаимодействий с соседями	Перелетные птицы в клиновидной формации. В стае выделяется лидер, задающий направление и скорость движения, а остальные ориентируются на него и соседей
Алгоритмы с ограниченной связностью, асинхронностью (sparse connectivity, asynchronous)	Граф взаимодействий может быть разреженным, агенты имеют небольшой набор соседей. Асинхронные агенты обновляют свои состояния в разные моменты времени, несинхронно	Муравьиные колонии или пчелиные рои. Отдельные представители обмениваются информацией нерегулярно, через локальные сигналы (феромоны, вибрации), и не все агенты связаны напрямую

Примечание. Названия дублируются на латинице для согласования с англоязычными исследованиями.

Практическая ценность. В навигации роя алгоритм согласования позволяет обеспечить выравнивание позиций или ориентаций агентов таким образом, чтобы они формировали линейные, кольцевые или окружные формации вокруг объекта либо двигались коллективно к заранее определенной цели. Такая постановка задачи находит применение в задачах патрулирования, обзорных миссий, где важно, чтобы рой реагировал синхронно и точно удерживал форму.

Реальная координация движения к общей цели без наличия централизованного контроля требует, чтобы каждый агент точно оценил свое локальное состояние и корректировал в соответствии с информацией от соседей. Это требует алгоритмического дизайна, который гарантирует отсутствие коллизий между агентами.

Использование алгоритмов согласования имеет несколько недостатков, которые относятся ко многим системам реального мира, включая неизбежность задержек передачи данных и возможность их потери. Беспроводные сети могут испытывать нестабильность из-за ограниченных вычислительных ресурсов агентов или их мощности обработки, что требует алгоритмов с низкой серьезностью расчетов, памяти и минимальной нагрузки на связь. Пример решения подобной задачи представлен в российских исследованиях на создание автономной визуальной навигации роя дронов без спутников (только на основе видеокамер) [3].

Топология связи между агентами оказывает значимое влияние на скорость и надежность согласования. Важным техническим решением являются адаптивные схемы связи, агенты динамически изменяют набор соседей или активность каналов связи в зависимости от загрузки и условий среды.

Сравнительный анализ, результат которого представлен на рис. 2, децентрализованных алгоритмов относительно централизованных демонстрирует, что удаление центрального узла обеспечивает лучшую отказоустойчивость, большую гибкость, упрощенную масштабируемость. При сравнении различных алгоритмов согласования по ключевым техническим критериям (скорости сходимости, устойчивости к сбоям и способности масштабироваться при росте числа агентов) видно алгоритмы с полной информацией и плотной связностью: они сходимы быстрее, но менее устойчивы к потерям связи и нагрузке. Алгоритмы с асинхронностью и ограниченной связностью более устойчивы, но могут требовать больше итераций и времени для достижения согласования.



Рис. 2. Результат сравнения алгоритмов по критериям

Использование искусственного интеллекта, в частности обучения с подкреплением, позволяет адаптировать алгоритмы согласования под изменяющиеся условия среды. Агент после обучения оптимизирует стратегию развития своего состояния, вес взаимодействия, работу при недостатке информации [4].

Обсуждение. Необходимо продолжить теоретические и экспериментальные исследования практического применения алгоритмов сопоставления: до сих пор наблюдается дефицит работ, в которых алгоритмы тестируются в реальных условиях с большим количеством агентов, с реальными ограничениями по коммуникациям, мощности и помехам.

Один из векторов развития связан с изучением гибридных алгоритмов, сочетающих преимущества подходов с лидером и полностью распределенных под-

ходов. Также перспективным представляется использование методов обучения с подкреплением для динамической корректировки весов взаимодействия между агентами: это позволит рою адаптироваться к внешним изменениям.

Заключение. В результате исследования удалось проанализировать тренды, вызовы и возможности применения алгоритмов согласования в задачах управления роем автономных агентов. Установлено соответствие между практическими задачами и алгоритмами согласования. Проведена параметризованная оценка эффективности алгоритмов, относящихся к роям. Рассмотрены недостатки и перечень прикладных задач. Выявлено, что алгоритмы среднего согласования эффективны на задачах, которые требуют равномерного распределения состояний, лидер-ведомые эффективны в задачах следования, алгоритмы ограниченной связности помогают улучшить аспект отказоустойчивости в условиях ненадежной связи. Обозначен вектор дальнейших изысканий.

Библиографический список

1. Mordor Intelligence. Рынок автономных агентов. URL: <https://www.mordorintelligence.com/ru/industry-reports/autonomous-agents-market> (дата обращения: 11.09.2025).
2. Математические основы автономных агентов // arXiv. URL: <https://arxiv.org/abs/math/0611932> (дата обращения: 12.09.2025).
3. Разработана система автономной визуальной навигации роя дронов // РАН. 25.04.2025. URL: <https://new.ras.ru/activities/news/razrabotana-sistema-avtonomnoy-vizualnoy-navigatsii-roya-dronov> (дата обращения: 16.09.2025).
4. Ученые и выпускники НГУ разработали систему автономного роевого поведения дронов // CNews. 24.06.2025. URL: https://www.cnews.ru/news/line/2025-06-24_uchenye_i_vypuskniki_ngu_razrabotali (дата обращения: 16.09.2025).
5. Харрис Ч. Сравнение микросервисной и монолитной архитектур // Atlassian. URL: <https://www.atlassian.com/ru/microservices/microservices-architecture/microservices-vs-monolith> (дата обращения: 21.09.2025).
6. Couzin I., Krause J., Franks N. et al. Effective leadership and decision-making in animal groups on the move // Nature. 2005. Vol. 433. P. 513–516. DOI [10.1038/nature03236](https://doi.org/10.1038/nature03236)

ANALYSIS OF THE APPLICATION OF CONSENSUS ALGORITHMS TO CONTROL A SWARM OF AUTONOMOUS AGENTS

Sharonov Nikita Sergeevich

Perm State University
15, Bukireva Str., Perm, Russia, 614990
69224@pspu.ru

The growing demand for swarm management methods for autonomous agents, such as mobile robots and autonomous transportation systems, highlights the relevance of consensus algorithms. These algorithms provide decentralized swarm management. This study is devoted to the analysis of fundamental consensus algorithms, as well as the study of their applicability to practical scenarios such as swarm navigation and cooperative goal achievement. Special attention is paid to the problems of real-world implementation and the impact of network topology on convergence and stability. The study highlights the practical potential of matching algorithms for swarm management and the need for applied research in a real-world environment.

Keywords: algorithms, consensus algorithms, multi-agent system, swarm, artificial intelligence

ПОИСК ФРАГМЕНТОВ НА КАРТЕ: ОТ КЛАССИЧЕСКИХ МЕТОДОВ К НЕЙРОННЫМ СЕТЯМ

Кобелев Виктор Антонович

АО «НИИ молекулярной электроники»
124460, Россия, г. Москва, г. Зеленоград, ул. Академика Валиева, д. 6, стр. 1
vkobelev@niime.ru

Тельминов Олег Александрович

АО «НИИ молекулярной электроники»
124460, Россия, г. Москва, г. Зеленоград, ул. Академика Валиева, д. 6, стр. 1
otelminov@niime.ru

Задача поиска фрагмента на карте является одной из ключевых в навигации беспилотного летательного аппарата. Классические методы компьютерного зрения показывают низкую эффективность, и в дальнейшем их применение в реальных условиях невозможно вследствие плохой точности. В данной работе представлено описание разработки системы для поиска фрагментов на карте на основе нейронной сети EfficientNetB0. Продемонстрированы этапы формирования датасета, обучения модели и результаты.

Ключевые слова: нейросетевые технологии, беспилотный летательный аппарат, компьютерное зрение, EfficientNet, датасет

Введение. Задача поиска небольшого фрагмента на большой карте – типичная проблема в навигации БПЛА. Считается, что алгоритмы наподобие поиска по шаблону (template matching) или SIFT (scale-invariant feature transform, алгоритм компьютерного зрения, который инвариантен к изменениям масштаба, поворота, шума и т.д.) должны легко справляться с ней [1]. Но на практике разработчики сталкиваются с серьезными ограничениями: масштабные искажения, атмосферные помехи, различия в цветовых палитрах картографических сервисов и – главное – необходимость высокой точности локализации.

Постановка задачи и формирование DataSet. Для создания нейросетевой системы поиска фрагмента на карте была поставлена следующая задача: по входному изображению необходимо определить местонахождение аппарата на карте размером 4352×4352 пикселей.

Входными параметрами системы являются: **I1** – пиксельное представление фрагмента карты, **I2** – пиксельное представление целевой карты, **M** – метаданные о координатах фрагментов целевой карты. В качестве выходных параметров системы используются: **D1** – координаты центра фрагмента на целевой карте (x, y), **D2** – вероятность совпадения.

Множество примеров для обучения сформировано на основе картографических данных, полученных из открытых источников. Для создания датасета были выполнены следующие действия:

- сборка большой карты размером 4352×4352 из 289 фрагментов;

- создание дополнительных фрагментов с искусственными шумами – атмосферными помехами, размытием, изменением масштаба и разного рода цветовыми искажениями.

Проектирование, обучение и тестирование нейросети. В основе системы лежит сиамская архитектура на EfficientNetB0 для сравнения двух картинок: маленького фрагмента и части большой карты. Сеть учится находить место, где фрагмент лучше всего «подходит» к карте. Для этого она строит «карту совпадений», где яркие точки – вероятные позиции фрагмента. Координаты берем из самой яркой области, а «уверенность» – из ее яркости [2–4].

Датасет из участков карт разбит в пропорции 80 на 20 на набор для обучения и валидации нейросетевой модели. Для исключения неоднозначности при работе сети при изменении масштаба и наклона последовательно используются:

- разбиение большой карты на квадраты и последующий их просмотр с небольшим перекрытием;
- проверка на нескольких приближенных и удаленных масштабах;
- незначительное сглаживание случайных ложных пиков в результате.

Обучение проводили в TensorFlow: сначала подстраивали верхнюю часть сети, затем дообучали всю модель. При обучении использовались:

- защита от переобучения с использованием алгоритма ранней остановки;
- приемы для аугментации датасета – случайное изменение масштаба и поворота, размытие, шум, сжатие JPEG, изменение яркости и цвета;
- добавление похожих, но заведомо неверных участков карты для обучения нейросети способности выявлять подобные фрагменты и исключать их из рассмотрения.

При валидации оценивали среднюю ошибку по пикселям, долю правильных попаданий в радиус 16–32 пикселей, время и память на обработку одной большой карты.

На тесте из 300 примеров получили среднюю ошибку 18 пикселей и точность 91% (попадание в радиус 32 пикселей).

По критерию скорости работы предлагаемая система примерно в 5 раз эффективнее классических методов (SIFT / ORB / поиск по шаблону) при сопоставимой или лучшей точности.

Заключение. В результате исследования создана нейросетевая система для поиска фрагмента на карте размером 4352×4352 пикселей. Это позволило ускорить процесс поиска местонахождения по сравнению с готовыми решениями из библиотек OpenCV. Ресурсов стало требоваться значительно меньше, а скорость обработки увеличилась в 5 раз по сравнению с классическими методами (SIFT, ORB). Средняя точность позиционирования составила 91% при ошибке в 18 пикселей, что является приемлемым результатом для дальнейшего применения в навигационных задачах БПЛА. Перспективы работы видятся в использовании более глубоких архитектур и применении методов аугментации, сильнее имитирующих реальные условия полета. В дальнейшем планируется аппаратная реализация на инференс-устройствах, основанных на традиционных нейропроцессорах (КМОП-технология [5]), или с применением элементной базы на новых физических принципах.

Библиографический список

1. Rublee E., Rabaud V., Konolige K., Bradski G. ORB: An Efficient Alternative to SIFT or SURF // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2011. P. 2564–2571. DOI 10.1109/ICCV.2011.6126544
2. Поляк Б. Т. Введение в оптимизацию. М.: Наука, 1983.
3. Koch G., Zemel R., Salakhutdinov R. Siamese Neural Networks for One-shot Image Recognition // ICML Deep Learning Workshop. 2015.
4. Bertinetto L., Valmadre J., Henriques J. F., Vedaldi A., Torr P. H. S. Fully-Convolutional Siamese Networks for Object Tracking // Computer Vision – ECCV 2016 Workshops. Springer, Cham, 2016. P. 850–865. DOI 10.1007/978-3-319-48881-3_56
5. Красников Г. Я., Горнев Е. С., Матюшкин И. В. Общая теория технологий и микроэлектроника. М.: Техносфера, 2020. 434 с. ISBN 978-5-94836-611-1.

MAP FRAGMENT SEARCH: FROM CLASSICAL METHODS TO NEURAL NETWORKS

KobeleV Viktor Antonovich

JSC “Research Institute of Molecular Electronics”
Bldg 1, 6, Academician Valiyev Str., Zelenograd, Moscow, 124460, Russia
vkobeleV@niime.ru

Telminov Oleg Aleksandrovich

JSC “Research Institute of Molecular Electronics”
Bldg 1, 6, Academician Valiyev Str., Zelenograd, Moscow, 124460, Russia
otelminov@niime.ru

The task of finding a fragment on a map is one of the key tasks in unmanned aerial vehicle navigation. Classical computer vision methods show low efficiency and their further application in real conditions is impossible due to poor accuracy. This paper presents a description of the development of a system for finding fragments on a map based on the EfficientNetB0 neural network. The stages of dataset formation, model training and results are demonstrated.

Keywords: neural network technologies, unmanned aerial vehicle, computer vision, EfficientNet, dataset

УДК 004.004.043

ПРИМЕНЕНИЕ АВТОКОДИРОВЩИКА ДЛЯ СНИЖЕНИЯ РАЗМЕРНОСТИ ПРИЗНАКОВ В ЗАДАЧЕ БИНАРНОЙ КЛАССИФИКАЦИИ ТЕМПЕРАТУРНЫХ АНОМАЛИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

Дёмин Кирилл Сергеевич

Волгоградский государственный университет
400062, Россия, г. Волгоград, проспект Университетский, 100
diominkirill@volsu.ru

Гермашев Илья Васильевич

Волгоградский государственный университет,
400062, Россия, г. Волгоград, проспект Университетский, 100
germashev@volsu.ru

В статье рассматривается применение автокодировщика для снижения размерности признакового пространства при анализе данных микроволновой радиотермометрии и клинических показателей в задаче бинарной классификации состояния тканей молочной железы для выявления температурных аномалий. В исследовании использованы исходные данные, включающие всего 70 признаков: радиотермометрические, на основе анамнеза и других медицинских показателей. Результаты показали, что при использовании 14 латентных признаков достигается оптимальный баланс диагностических метрик: чувствительность составила 0.906 против 0.878 для исходных признаков, а специфичность 0.890 против 0.906 соответственно.

Ключевые слова: искусственные нейронные сети, автокодировщик, классификация, молочная железа, радиотермометрия

Введение. Современные методы машинного обучения находят широкое применение в медицинской диагностике, в частности при анализе признаков, полученных в ходе клинических исследований и сбора анамнеза. Однако высокая размерность признакового пространства часто приводит к проблемам: ухудшению обобщающей способности моделей, увеличению вычислительной сложности и снижению интерпретируемости [1, 2]. Классические методы снижения размерности, такие как метод главных компонент или регуляризация L1 (Lasso), обладают ограниченной способностью учитывать нелинейные зависимости между признаками.

В данной работе рассматривается применение автокодировщика для сжатия исходного признакового пространства, включающего температурные показатели и клинические параметры. Автокодировщик позволяет построить компактное латентное представление данных, сохранив при этом их ключевую информацию.

¹ © Дёмин К. С., Гермашев И. В., 2025

Цель настоящей работы заключается в исследовании применения автокодировщика для сокращения размерности признакового пространства в задаче бинарной классификации с медицинскими данными и сравнения качества классификации при использовании исходных и сжатых признаков. В качестве основных метрик оценки применяются чувствительность и специфичность, которые имеют критическое значение при выявлении температурной аномалии молочной железы, свидетельствующей о высоком риске наличия патологий, в том числе рака молочной железы.

Особое внимание уделено выбору оптимальной размерности латентного пространства. Для этого проведен перебор значений размерности признакового пространства с последующим обучением классификатора. Сравнение значений метрик до и после сжатия позволяет выявить наиболее информативное представление признаков и определить потенциал автокодировщика как инструмента предобработки данных в медицинских задачах.

Исходные данные. Для исследования использовались клинические данные, собранные с применением микроволновой радиотермометрии, предназначенной для оценки температурных характеристик тканей молочной железы. Данные включают как температурные измерения (кожные и внутренние измерения), так и дополнительные клинические и анамнестические показатели пациента, указанные в табл. 1.

Таблица

Клинические и анамнестические показатели пациента

Признак	Единица измерения
Возраст	Лет
Диаметр молочной железы	Сантиметров
Индекс массы тела	0 – очень худая; 1 – худая; 2 – нормальная; 3 – полная; 4 – очень полная
Гормональная зависимость	1 – да / 0 – нет
Жалобы на боли в груди	1 – да / 0 – нет
Количество беременностей	Штук
Количество рожденных детей	Штук
Возраст на момент первых родов	Лет

Обучающая выборка состояла из данных 7446 измерений молочных желез, разделенных на 2 класса, а тестовая из 1864. Для классификации были выделены температурные признаки на основе математического моделирования, полученные в работе [3], а также перечисленные клинические показатели из табл. 1. Бинарная классификация представляет значение состояния ткани (наличие температурных аномалий – 1 / отсутствие температурных аномалий – 0). Таким образом, размерность исходного признакового пространства равна 70 (62 температурных признака и 8 признаков из табл. 1). Тестовая выборка никак не участвует в процессе сжатия размерности, а служит только для проверки обобщающей способности. Для обеспечения сопоставимости признаков и улучшения сходимости нейросетевых моделей все признаки приведены к нормальному распределению со средним значением 0 и стандартным отклонением 1.

Архитектура автокодировщика. Для снижения размерности признакового пространства использовался автокодировщик, состоящий из кодировщика и декодировщика. Архитектура кодировщика включала последовательные полносвязные слои: 50 и 30 нейронов с функцией активации ReLU [4], завершающий слой «бутылочного горлышка» имел переменную размерность от 20 до 10. Декодировщик зеркально повторял структуру кодировщика, восстанавливая исходное число признаков. Автокодировщик обучался минимизации функции среднеквадратичной ошибки между входными и восстановленными признаками. Для предотвращения переобучения использовалась кросс-валидация с делением на 5 частей (фолдов). Обучение проводилось 50 эпохами. После обучения автокодировщика извлекались латентные признаки из слоя «бутылочного горлышка». Эти признаки представляли собой нелинейное преобразование исходного признакового пространства в пространство с меньшей размерностью латентных признаков, сохраняющее наиболее информативные вариации признаков, важные для классификации.

Классификация и оценка качества. Для оценки диагностической значимости признаков применялась логистическая регрессия на исходных и латентных признаках. Основными метриками оценки качества классификации были чувствительность (Sens) и специфичность (Spec), рассчитываемые по матрице ошибок следующим образом:

$$\text{Sens} = \frac{TP}{TP + FN}, \quad \text{Spec} = \frac{TN}{TN + FP},$$

где TP – число истинно положительных случаев, TN – число истинно отрицательных, FP – ложноположительные, FN – ложноотрицательные.

Для выявления оптимальной размерности латентного пространства проводился перебор значений от 20 до 10 с шагом 1 на основе наблюдений в работе [5], где использовался аналогичный набор данных и модель классификации. Для каждого размера обучался автокодировщик, извлекались латентные признаки и обучался классификатор. Результаты чувствительности и специфичности представлены на рис. 1.




Рис. 1. Результаты чувствительности и специфичности при уменьшении размерности

Исходя из данных рис. 1, видим, что наилучшим по показателям стала модель на основе 14 латентных признаков.

Результаты и обсуждение. В ходе исследования сравнены две модели бинарной классификации тканей молочной железы на основе микроволновой радиотермометрии и анамнестических данных на тестовых данных, которые не участвовали в процессе снижения размерности признаков.

Использование исходных признаков показало результаты:

- чувствительность равна 0.878;
- специфичность равна 0.906.

Использование латентных признаков автокодировщика (латентное пространство размерности 14) показало результаты:

- чувствительность равна 0.906;
- специфичность равна 0.890.

Графическое сравнение этих метрик представлено на рис. 2.




Рис. 2. Сравнение значений чувствительности и специфичности

Исходя из данных рис. 2, можно сделать вывод о том, что сжатие признаков с помощью автокодировщика позволило увеличить чувствительность, что критично для медицинской диагностики, так как снижает риск пропуска патологических случаев.

Небольшое снижение специфичности указывает на легкое увеличение ложноположительных срабатываний, что в клиническом контексте менее критично, чем снижение чувствительности. Таким образом, применение автокодировщика обеспечивает лучший баланс между выявлением патологии и уменьшением размерности данных.

Заключение. В результате исследования построен автокодировщик для снижения размерности признакового пространства в задаче бинарной классификации на основе данных микроволновой радиотермометрии и клинических пока-

зателей. Автокодировщик позволяет уменьшить размерность исходного пространства с 70 до 14 информативных латентных признаков без потери качества классификации. Чувствительность классификации увеличивается при использовании сжатых признаков (0.906 против 0.878 для исходных), что снижает риск пропуска патологических случаев. При этом наблюдается небольшое снижение специфичности (0.890 против 0.906), что в клиническом контексте менее критично, чем снижение чувствительности.

Библиографический список

1. Ahadzadeh B., Abdar M., Safara F., Khosravi A., Menhaj M. B., Suganthan P. N. SFE: A Simple, Fast, and Efficient Feature Selection Algorithm for High-Dimensional Data // IEEE Transactions on Evolutionary Computation. 2023. Vol. 27, no. 6. P. 1896–1911. DOI [10.1109/TEVC.2023.3238420](https://doi.org/10.1109/TEVC.2023.3238420)
2. Jianqing F., Jinchi Lv. A Selective Overview of Variable Selection in High Dimensional Feature Space // Statistica Sinica. 2009. Vol. 20, no. 1. P. 101–148. URL: <https://pubmed.ncbi.nlm.nih.gov/21572976/>
3. Лосев А. Г., Левшинский В. В. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной // Математическая физика и компьютерное моделирование. 2017. Т. 20, № 5. С. 49–62. DOI 10.15688/mpcm.jvolsu.2017.5.6
4. Bai Yu. RELU-Function and Derived Function Review // SHS Web of Conferences, vol. 144. 2022. Article 02006. DOI [10.1051/shsconf/202214402006](https://doi.org/10.1051/shsconf/202214402006)
5. Дёмин К. С., Гермашев И. В. Рекурсивный отбор признаков развития рака молочной железы на данных скрининга радиотермометрии // Математические методы в технологиях и технике. 2025. № 5. С. 59–63.

APPLICATION OF AUTOENCODER FOR FEATURE DIMENSIONALITY REDUCTION IN A BINARY CLASSIFICATION TASK OF TEMPERATURE ANOMALIES OF THE BREAST

Kirill S. Dyomin

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

Ilya V. Germashev

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

This paper examines the application of an autoencoder for reducing the dimensionality of the feature space when analyzing microwave radiothermometry data and clinical indicators in the task of binary classification of breast tissue conditions. The study utilized raw data comprising 62 radiothermometric features and 8 additional anamnesis parameters. The results demonstrated that using 14 latent features achieves an optimal balance of diagnostic metrics: sensitivity reached 0.906 compared to 0.878 for the original features, while specificity amounted to 0.890 versus 0.906, respectively.

Keywords: artificial neural networks, autoencoder, classification, mammary gland, radiothermometry

ИНТЕРПРЕТИРУЕМАЯ СИСТЕМА КООРДИНАТ УРОВНЕЙ ВЫРАЖЕННОСТИ ТЕМПЕРАТУРНЫХ АНОМАЛИЙ

Ермолович Элла Юрьевна

Волгоградский государственный университет
4000062, Россия, г. Волгоград, проспект Университетский, 100
ella.ermolovitch@gmail.com

Работа посвящена проблеме несоответствия традиционной линейной классификации результатов микроволновой радиотермометрии реальной структуре данных. В рамках исследования проводится анализ расположения уровней выраженности температурных аномалий на плоскости и рассматривается возможность создания интерпретируемой системы координат, позволяющей повысить диагностическую ценность метода.

Ключевые слова: аффинная система координат, интерпретация данных, многомерные данные, классификация

Введение. При анализе многомерных данных часто возникает вопрос о природе наблюдаемых структур. В частности, при изучении групп уровней выраженности температурных аномалий традиционно предполагалось, что полученные термографические показатели образуют упорядоченную шкалу градаций, отражающих интенсивность патологических изменений.

В современной медицине уделяется особое внимание методам определения пациентов, находящихся в группе риска по развитию онкологических заболеваний [1]. В случае рака молочной железы особую эффективность демонстрирует метод микроволновой радиотермометрии, позволяющий неинвазивно выявлять температурные аномалии на глубине нескольких сантиметров. Эти измерения преобразуются в диагностически значимые параметры, которые, наряду с информацией о пациенте (анамнез, диагноз, стадия заболевания), хранятся в специализированной базе данных. В результате диагностики молочные железы описываются классами th по шкале [2]:

- th_0 – отсутствие температурных аномалий;
- th_1 – характерных признаков рака молочной железы не выявлено, наблюдается участок понижения температуры;
- th_2 – характерных признаков рака молочной железы не выявлено, наблюдается участок повышения температуры;
- th_3 – группа риска;
- th_4 – множественные температурные аномалии;
- th_5 – острое воспаление, рак.

Материалы и методы. Анализируемая база данных искусственно сбалансирована количественно и содержит информацию о 6000 пациентах (1000 объектов в каждом из классов th). В качестве начального шага проводится нормализация данных в диапазоне $[0,1]$ по формуле

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}},$$

где X – исходное значение признака, X_{min} – минимальное значение в наборе данных, X_{max} – максимальное значение в наборе данных, X_{norm} – нормализованное значение.

Далее выбираются центроиды для каждого класса th по десяти наиболее информативным признакам [3] с низкой корреляцией. Путем вычисления медианы для массива значений объектов, принадлежащих определенному классу, по всем признакам получаем 10-мерные вектора (центроиды).

Применение метода главных компонент (РСА) к данным радиотермометрии молочных желез выявило нетривиальную пространственную организацию диагностических классов $th0$ – $th5$ в пространстве признаков. Оси (главные компоненты) в методе главных компонент (РСА) показывают направления, вдоль которых данные варьируются наиболее существенно. В двумерной проекции наблюдалось разделение классов на две группы (рис. 1):

- 1) $th0$, $th2$, $th4$, $th5$ образуют линию вдоль оси Y (главная компонента РС2);
- 2) $th1$ и $th3$ формируют отдельный кластер, смещенный относительно первой группы по оси X (главная компонента РС1).




Рис. 1. Результат применения метода главных компонент для двух главных компонент

Заметно, что центроиды образуют две линии, выходящие из точки $th0$. В результате такого наблюдения появилась идея преобразования прямых в систему координат, с началом координат в точке $th0$ и новыми осями v (на которой лежат

th2, th4, th5) и u (на которой лежат th1, th3), в результате такого преобразования получается интерпретируемая система координат. Объекты распределяются следующим образом: в первой четверти – «смежные» классы, во второй – классы th1, th3, в третьей – класс th0, а в четвертой – классы th2, th4, th5. Необходимо отдельно отметить, что объекты, располагающиеся близко к началу координат в любой четверти, могут классифицироваться как th0.

Пусть у нас есть точки-центроиды $C_0, C_1, \dots, C_5 \in R^2$. Определим для них точки, по которым будут строиться новые оси: $A = C_0, B = C_3, C = C_5$.

На основе этих точек определим векторы для дальнейших преобразований:

$$u = B - A = C_3 - C_0,$$

$$v = C - A = C_5 - C_0.$$

Переносим начало координат в точку A . Теперь любую точку $P = (x, y)$ выражаем как

$$P = A + \alpha u + \beta v.$$

То есть координаты (α, β) в новой системе находятся из уравнения

$$P - A = \alpha u + \beta v.$$

Запишем в матричном виде:

$$\begin{bmatrix} u_x & v_x \\ u_y & v_y \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} x - x_A \\ y - y_A \end{bmatrix}.$$

Обозначим матрицу перехода M :

$$M = \begin{bmatrix} u_x & v_x \\ u_y & v_y \end{bmatrix},$$

тогда

$$\begin{bmatrix} \alpha \\ \beta \end{bmatrix} = M^{-1} \cdot (P - A),$$

$$\alpha = \frac{(x - x_A)v_y - (y - y_A)v_x}{\det M}, \quad \beta = \frac{u_x(y - y_A) - u_y(x - x_A)}{\det M}.$$

I четверть ($\alpha > 0, \beta > 0$): объекты из «смежных» классов.

II четверть ($\alpha < 0, \beta > 0$): классы th1, th3.

III четверть ($\alpha < 0, \beta < 0$): класс th0.

IV четверть ($\alpha > 0, \beta < 0$): классы th2, th4, th5.

Таким образом, все преобразование есть аффинное преобразование с переносом начала в $A = th0$ и изменением базиса на (u, v) , что делает систему коор-

динат интерпретируемой: разные группы центроидов оказываются разведены по четвертям новой системы координат (рис. 2).




Рис. 2. Новая система координат

Закключение. В результате продемонстрировано, что уровни выраженности температурных аномалий, по сути, не являются уровнями, а образуют две линии уровня, что позволяет построить интерпретируемую систему координат.

Библиографический список

1. Лосев А. Г., Мазепа Е. А., Замечник Т. В. О некоторых характерных признаках в диагностике патологии молочных желез по данным микроволновой радиотермометрии // Современные проблемы науки и образования. 2014 № 6. С. 254.
2. Замечник Т. В., Лосев А.Г., Петренко А. Ю. Управляемый классификатор в диагностике рака молочной железы по данным микроволновой радиотермометрии // Математическая физика и компьютерное моделирование. 2019. Т. 22, № 3. С. 52–66.
3. Левшинский В. В. Математические методы анализа и интерпретации термометрических данных в медицинской диагностике: дис. ... канд. техн. наук. 2022. 202 с.

INTERPRETABLE COORDINATE SYSTEM OF LEVELS OF EXPRESSION OF TEMPERATURE ANOMALIES

Ermolovich Ella Urievna

Volgograd State University
100, Universitetsky Ave., Volgograd, Russia, 4000062
ella.ermolovitch@gmail.com

This paper examines the discrepancy between the traditional linear classification of microwave radiothermometry results and the actual data structure. The study analyzes the distribution of temperature anomaly severity levels on a plane and explores the possibility of creating an interpretable coordinate system that could enhance the diagnostic value of the method.

Keywords: affine coordinate system, data interpretation, multivariate data, classification

НЕЙРОСЕТЕВАЯ СИСТЕМА ДИАГНОСТИКИ И ПРОГНОЗИРОВАНИЯ РАЗВИТИЯ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ KARDIONET КАК ИСТОЧНИК ПОЛУЧЕНИЯ НОВЫХ МЕДИЦИНСКИХ ЗНАНИЙ

Думлер Андрей Артурович

Пермский государственный медицинский университет
им. Академика Е.А. Вагнера
614000, г. Пермь, ул. Петропавловская, д. 26
ivan.ivanovskii.2000@mail.ru

Каракулова Юлия Владимировна

Пермский государственный медицинский университет
им. Академика Е.А. Вагнера
614000, г. Пермь, ул. Петропавловская, д. 26
julia.karakulova@mail.ru

Ясницкий Леонид Нахимович

Пермский государственный национальный
исследовательский университет
614600, г. Пермь, ул. Букирева, 15
yasn1949@mail.ru

В статье представлены данные использования нейросетевой системы CardioNet для получения новых медицинских данных, таких как «парадокс курильщика», «парадокс физкультуры», меняющие традиционные представления о профилактике сердечно-сосудистых заболеваний и требующие дальнейшего изучения и объяснения.

Ключевые слова: сердечно-сосудистые заболевания, нейросетевая система диагностики, ишемическая болезнь сердца, «парадокс курильщика», «парадокс физкультуры»

Введение. Интеллектуальная нейросетевая система «Кардионет», предназначенная для выявления острого коронарного синдрома, показала свою эффективность в выявлении сердечно-сосудистых заболеваний как на догоспитальном этапе в условиях работы бригады скорой медицинской помощи (4,3% ошибочных диагнозов), так и в условиях работы специализированного кардиологического отделения (100% правильно поставленных диагнозов) [1–3].

Это позволило рекомендовать использование «Кардионет» в работе первичного звена учреждений здравоохранения. Нами же было проведено сценарное прогнозирование путем выполнения виртуальных экспериментов. Например, поставив с помощью диагностической системы какому-либо пациенту диагноз, можно попробовать поварьировать его входные параметры, увеличив возраст пациента на 10 или 20 лет, можно спрогнозировать, как будут развиваться его заболевания в будущем. Можно попытаться улучшить прогнозные диагнозы пациента путем коррекции некоторых входных параметров, например смоделировать изменение образа жизни пациента, отказаться от злоупотребления кофе, курением, наркотиками, изменить диету, заняться спортом и т.д. В результате наблюдения

за соответствующими изменениями-откликами выходного вектора диагностической системы можно выполнить прогнозирование состояния здоровья пациента в зависимости от изменяемых входных параметров и разработать на основании таких прогнозов полезные рекомендации: оптимальный образ жизни и приверженность лечению [2].

Однако при проведении сценарного моделирования оказалось, что у части пациентов (порядка 6% из всей выборки) такие рекомендации, как отказ от курения, снижение массы тела и регулярные аэробные физические нагрузки, увеличивают риск развития сердечно-сосудистых заболеваний (в частности, повторного инфаркта миокарда, аритмий и блокад сердца, хронической сердечной недостаточности).

Анализ литературы показал, что выявленные нейросетью парадоксальные результаты не являются новыми и были установлены ранее. Так, John A. Baron в обзорной статье 1996 г. указывает на антитромботический эффект курения. Существуют *in vitro* доказательства того, что никотин и котинин могут подавлять синтез простагландинов, включая тромбоксан, мощный проагрегационный простаноид. Эти прямые простагландин-ингибирующие эффекты никотина предположительно могут приводить к снижению риска тромбоза, хотя еще предстоит доказать, что эффекты *in vitro* имеют клиническое значение *in vivo* [4].

В исследовании Gabriel I. Barbash et al [5] на основании ретроспективного анализа выявлено, что курильщики, получающие тромболитическую терапию после острого инфаркта миокарда, имеют значительно лучший исход в стационаре и через 6 месяцев, чем некурящие или бывшие курильщики. Однако курильщики перенесли инфаркт в значительно более раннем возрасте, чем некурящие, и следует продолжать прилагать активные усилия для уменьшения числа новых и продолжающих курение. В этом исследовании были приведены статистические данные без исследования наблюдаемого эффекта.

Полученные данные требуют дальнейшего исследования и требуют с осторожностью относиться к общей рекомендации немедленного отказа от курения у кардиологических больных.

Важным аспектом профилактики заболеваний сердца и сосудов является снижение массы тела. Так, в работе Hyun-Jung Lee [6] на основе обследования большой группы лиц с фибрилляцией предсердий доказана негативная роль вариабельности массы тела, особенно в сторону его снижения, как фактора риска развития фибрилляции предсердий.

В исследовании June Stevens et al. [7] показано, что среди взрослых среднего возраста краткосрочная (3-летняя) потеря веса более чем на 3% была связана с повышенным непосредственным риском ИБС (отношение рисков = 1,46, 95%) и риском инсульта (отношение рисков = 1,45, 95%). Риск, как правило, был выше у взрослых, у которых потеря веса не происходила из-за диеты. Избегание увеличения веса в раннем и среднем зрелом возрасте может снизить риск ИБС и инсульта, но кратковременная непреднамеренная потеря веса в среднем зрелом возрасте может быть индикатором немедленного повышенного риска, который ранее не был хорошо изучен.

Одной из распространенных рекомендаций кардиолога бывает предложение больному заняться регулярными физическими нагрузками с достижением суб-

максимальной частоты сокращений сердца. При этом стоит обратить внимание на работу Thijs M. H. Eijssvogels [8], где приводятся угрожающие данные. Пожилые люди умирают во время упражнений в основном от ишемической болезни сердца. Острая эрозия или разрыв атеросклеротической бляшки, ведущие к острому коронарному тромбозу, выявляются у большинства ранее бессимптомных лиц, которые умирают или страдают от инфаркта миокарда во время физических упражнений. У некоторых явно бессимптомных лиц обнаруживается только прогрессирующая ИБС без признаков острого разрушения бляшек, что позволяет предположить, что ишемия сердца сама по себе также может вызывать нестабильную стенокардию во время упражнений. Разрушение бляшек во время упражнений связано с увеличением сдвигающих сил, связанных с упражнениями, а также с увеличением изгиба и сгибания эпикардиальных коронарных артерий во время упражнений. Сгибание коронарных артерий увеличивается во время упражнений за счет увеличения частоты сердечных сокращений. Кроме того, увеличение конечного диастолического объема левого желудочка и уменьшение конечного систолического объема требует большей экскурсии и, следовательно, изгиба эпикардиальных коронарных артерий во время нагрузки. Такое изгибание атеросклеротических артерий с жесткостью может вызвать или усугубить растрескивание и разрыв бляшки.

В работе Roberta Florido et al. [9] показано, что регулярные физические нагрузки были связаны со снижением риска сердечной недостаточности у пациентов с артериальной гипертензией, ожирением, сахарным диабетом и метаболическим синдромом. Несмотря на это, у пациентов с атеросклеротическим сердечно-сосудистым заболеванием регулярные физические нагрузки могут иметь более слабую связь с профилактикой сердечной недостаточности после установления диагноза ишемической болезни сердца.

Примечательно, что аналогичные данные были выявлены с помощью KardioNet. Многим из этих фактов еще предстоит дать объяснение, прежде всего выявить факторы, влияющие на прогноз заболевания. Это потребует целой серии виртуальных экспериментов, которые мы планируем провести в ближайшее время. Тем не менее мы предлагаем в случае подбора индивидуальных программ пациенту более аккуратно относиться к рекомендациям по борьбе с вредными привычками, снижению максы тела и физической активности.

Поддержка исследований. Работы ведутся в рамках госзадания EZID-2025-0003 «Разработка технологий снижения смертности населения от сердечно-сосудистых заболеваний в целях их применения в системе здравоохранения (диспансеризация) на основе ранней диагностики, профилактики и телемедицинской оценки реабилитационных мероприятий» № 1024022200061-2-3.1.4; 3.2.25; 1.2.1».

Библиографический список

1. Yasnitsky L. N., Dumler A. A., Poleshchuk A. N., Bogdanov C. V., Cherepanov F. M. Artificial Neural Networks for Obtaining New Medical Knowledge: Diagnostics and Prediction of Cardiovascular Disease Progression // *Biology and Medicine*. 2015. Vol. 7, no. 2. Article BM-095-15. 8 p.
2. Yasnitsky L. N., Dumler A. A., Cherepanov F. M., Uteva N. A. Capabilities of neural network technologies for extracting new medical knowledge and enhancing precise decision making for patients // *Expert Review of Precision Medicine and Drug Development*. 2022. Vol. 7, iss. 1. P. 70–78. DOI [10.1080/23808993.2021.1993595](https://doi.org/10.1080/23808993.2021.1993595)

3. Yasnitsky L. N., Dumler A. A., Cherepanov F. M. Dynamic artificial neural networks as basis for medicine revolution // *Advances in Intelligent Systems and Computing*. 2018. Vol. 850. P. 351–358.
4. Baron J. A. Beneficial effects of nicotine and cigarette smoking: the real, the possible and the spurious // *British Medical Bulletin*. 1996. Vol. 52, no. 1. P. 58–73. DOI [10.1093/oxfordjournals.bmb.a011533](https://doi.org/10.1093/oxfordjournals.bmb.a011533)
5. Barbash G. I., White H. D., Modan M. et al. Significance of smoking in patients receiving thrombolytic therapy for acute myocardial infarction. Experience gleaned from the International Tissue Plasminogen Activator/Streptokinase Mortality Trial // *Circulation*. 1993. Vol. 87, no. 1. P. 53–58. DOI [10.1161/01.cir.87.1.53](https://doi.org/10.1161/01.cir.87.1.53).
6. Lee H. J., Choi E. K., Han K. D. et al. Bodyweight fluctuation is associated with increased risk of incident atrial fibrillation // *Heart rhythm*. 2020. Vol. 17, no. 3. P. 365–371. DOI [10.1016/j.hrthm.2019.09.029](https://doi.org/10.1016/j.hrthm.2019.09.029)
7. Stevens J., Erber E., Truesdale K. P. et al. Long- and short-term weight change and incident coronary heart disease and ischemic stroke: the Atherosclerosis Risk in Communities Study // *American Journal of Epidemiology*. 2013. Vol. 178, no. 2. P. 239–248. DOI [10.1093/aje/kws461](https://doi.org/10.1093/aje/kws461)
8. Eijssvogels T. M. H., Fernandez A. B., Thompson P. D. Are There Deleterious Cardiac Effects of Acute and Chronic Endurance Exercise? // *Physiological Reviews*. 2016. Vol. 96, no. 1. P. 99–125. DOI [10.1152/physrev.00029.2014](https://doi.org/10.1152/physrev.00029.2014)
9. Florido R., Kwak L., Lazo M. et al. Physical Activity and Incident Heart Failure in High-Risk Subgroups: The ARIC Study // *Journal of the American Heart Association*. 2020. Vol. 9 (10). e014885. DOI [10.1161/JAHA.119.014885](https://doi.org/10.1161/JAHA.119.014885)

KARDIONET, A NEURAL NETWORK SYSTEM FOR DIAGNOSTICS AND PREDICTION OF CARDIOVASCULAR DISEASE DEVELOPMENT AS A SOURCE OF NEW MEDICAL KNOWLEDGE

Andrey A. Dumler

Perm State Medical University named after Academician E.A. Wagner
614000, Perm, Petropavlovskaya St., Bldg. 26
ivan.ivanovskii.2000@mail.ru

Юлия В. Каракулова

Perm State Medical University named after Academician E.A. Wagner
614000, Perm, Petropavlovskaya St., Bldg. 26
julia.karakulova@mail.ru

Леонид Н. Ясницкий

Perm State National Research University
15 Bukireva Street, Perm, 614600
yasn1949@mail.ru

This article presents data from the use of the KardioNet neural network system to obtain new medical data, such as the "smoker's paradox" and the "exercise paradox," which challenge traditional understanding of cardiovascular disease prevention and require further study and explanation.

Keywords: cardiovascular disease, neural network diagnostic system, coronary heart disease, "smoker's paradox," "exercise paradox"

ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И БИОИМПЕДАНСНОЙ СПЕКТРОСКОПИИ ДЛЯ КЛАССИФИКАЦИИ ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ ОРГАНОВ И СИСТЕМ ЧЕЛОВЕКА

Корсунский Никита Александрович

Шаталова Ольга Владимировна

Юго-Западный государственный университет
305040, Россия, г. Курск, ул. 50 Лет октября, 94
cor.nick2013@yandex.ru

Старцев Евгений Александрович

Воронежский государственный технический университет
394006, Россия, г. Воронеж, ул. 20-летия Октября, 84
starcev_evgeniy@mail.ru

Представлены результаты разработки метода диагностики вирусных заболеваний дыхательной системы на основе биоимпедансной спектроскопии и алгоритмов искусственного интеллекта. В работе описан процесс формирования информативных признаков, создание гибридного классификатора и клиническая апробация. Методика продемонстрировала высокую диагностическую эффективность и сопоставимость с традиционными инструментальными подходами.

Ключевые слова: биоимпедансная спектроскопия, искусственный интеллект, гибридная нейронная сеть, нечеткая логика, медицинские решения

Введение. Заболевания органов дыхания остаются ведущей причиной заболеваемости и смертности во всем мире [1, 2]. Особенно важной задачей является раннее выявление вирусной пневмонии и ее дифференциация от ОРВИ. Стандартные методы визуализации, такие как рентгенография и компьютерная томография, информативны, но сопряжены с лучевой нагрузкой и ограниченной доступностью для частого применения [3].

Альтернативой является биоимпедансная спектроскопия (БИС), основанная на измерении электрических свойств тканей. Метод безопасен, доступен и позволяет многократный мониторинг пациента. Применение алгоритмов искусственного интеллекта (ИИ) позволяет автоматизировать интерпретацию данных и повысить точность диагностики [4, 5].

Методы. Исследования выполнялись с применением многочастотной БИС. Использовались восемь квазиортогональных отведений, что позволило регистрировать амплитудно-фазово-частотные характеристики (АФЧХ) и формировать векторы признаков.

Существуют три подхода анализа биоимпеданса: Т-модальный (динамика изменений во времени), F-модальный (частотные характеристики) и А-модальный (анализ анизотропии проводимости тканей). В данной работе применялись все три подхода.

Формирование дескрипторов проводилось путем разбиения частотного диапазона на поддиапазоны и вычисления медианных значений. Полученные данные использовались для обучения гибридного классификатора, состоящего из нескольких модулей нейросетевого анализа и агрегатора решений.

На рис. 1 представлена топология размещения электродов, используемая в исследовании.




Рис. 1. Топология размещения электродов при проведении биоимпедансных исследований в четырех ортогональных отведениях в области грудной клетки и брюшной полости

После изучения АФЧХ биоимпеданса для реальной части АФЧХ было установлено, что разумно разделить амплитудный диапазон $\text{Re}(m)$ на шесть поддиапазонов (рис. 2) [6, 7].




Рис. 2. Пример формирования вектора информативных признаков по фактической части биоимпеданса

Измерительный комплекс. Для проведения исследований создан специализированный измерительный комплекс. Его основу составляет модуль сбора данных E20-10 (L-Card), включающий высокоскоростной АЦП и ЦАП. К модулю подключается разработанный 8-канальный мультиплексор, обеспечивающий коммутацию сигналов от различных пар электродов без необходимости их перестановки [8].

На рис. 3 приведена структурная схема прибора, включающего модуль сбора данных, преобразователь «ток – напряжение» и блок связи с биологическим объектом.





Рис. 3. Структурная схема прибора для биоимпедансной спектроскопии

Для расширения возможностей применялся мультиплексор, основанный на аналоговых ключах. Его электрическая схема представлена на рис. 4 [9, 10].



Примечание. Отображены дифференциальные входные пары каналов S1A/S1B – S4A/S4B, общие выходы DA, DB и цифровые линии управления (A0, A1, EN), входы и выходы, идущие на АЦП(ADC) и ЦАП(DAC).

Рис. 4. Схематическая иллюстрация двух 8-канальных мультиплексора DG409

В состав комплекса также входит программный модуль для настройки параметров сигнала: выбор формы тока (синусоидальный или прямоугольный), амплитуды, частотного диапазона и активных каналов. Интерфейс программы обеспечивает отображение результатов измерений и их предварительный анализ. Его окна представлены на рис. 5 и 6.

Результаты. Классификатор медицинского риска имеет трехуровневую иерархическую структуру (рис. 7). На первом уровне имеем 16 слабых классификаторов (NET1...NET16), соответствующих 16 отведениям, которые могут быть получены посредством восьми электродов с топологией, представленной на рис. 1. На втором иерархическом уровне имеем четыре слабых классификатора, которые объединяют решения классификаторов первого уровня, работающих с дескрипторами, полученными на отведениях, лежащих в одних и тех же плоскостях. Всего имеем четыре плоскости, в которых формируются отведения. В первых двух (горизонтальные плоскости, рис. 1) имеем по шесть отведений, в последних двух – вертикальные плоскости) имеем по два отведения. В каждом отведении определяются по шесть дескрипторов для мнимой и действительных частей графика Коула соответственно (рис. 2) [5–7].




Рис. 5. Окно настройки параметров биоимпедансного исследования в программном модуле




Рис. 6. Результаты биоимпедансного исследования, полученные одновременно для семи пар электродов посредством мультимплексора




Рис. 7. Структурная схема классификатора

Каждый классификатор первого уровня настраивается автономно по соответствующему набору данных. Агрегатор NET 3 построен на основе полносвязной нейронной сети. Для его обучения используются результаты классификации данных, поступающих с выходов классификаторов второго уровня (NET 2) [11]. Учитывая, что отведения формируются последовательно во времени, решения классификаторов второго уровня хранятся в запоминающем устройстве (ЗУ).

Клинические испытания проводились на трех группах пациентов: с вирусной пневмонией, с ОРВИ и здоровыми добровольцами. Результаты показали выраженные отличия между группами. Чувствительность метода составила до 91%, специфичность – до 89%.

Заключение

1. Разработан специализированный измерительный комплекс для БИС, включающий модуль сбора данных и 8-канальный мультиплексор.

2. Создан программный модуль для настройки параметров и визуализации данных.

3. Проведена клиническая апробация, показавшая высокие показатели чувствительности и специфичности.

4. Методика может быть внедрена в практику ранней диагностики заболеваний дыхательной системы.

Библиографический список

1. Шаталова О. В., Серебровский А. В., Стадниченко Н. С. и др. Биоимпедансная спектроскопия в классификаторах функционального состояния органов и систем человека, построенных на основе гибридных технологий искусственного интеллекта // Системный анализ и управление в биомедицинских системах. 2023. Т. 22, № 2. С. 100–113. DOI [10.36622/VSTU.2023.22.2.015](https://doi.org/10.36622/VSTU.2023.22.2.015)

2. Мирошников А. В., Стадниченко Н. С., Шаталова О. В., Филист С. А. Модели импеданса биоматериала для формирования дескрипторов в интеллектуальных системах диагностики инфекционных заболеваний // Моделирование, оптимизация и информационные технологии. 2020. Т. 8, № 4 (31). С. 1–14. DOI [10.26102/2310-6018/2020.31.4.018](https://doi.org/10.26102/2310-6018/2020.31.4.018)

3. Торнуев Ю. В., Непомнящих Д. Л., Никитюк Д. Б. и др. Диагностические возможности неинвазивной биоимпедансометрии // Фундаментальные исследования. 2014. № 10-4. С. 782–788.

4. Серебровский А. В., Корсунский Н. А., Лях А. В. и др. Мультимодальный классификатор медицинского риска на основе многоэлектродного биоимпедансного преобразователя // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С. 121–143. DOI [10.21869/2223-1536-2024-14-3-121-143](https://doi.org/10.21869/2223-1536-2024-14-3-121-143)

5. Мирошников А. В., Шаталова О. В., Стадниченко Н. С., Шульга Л. В. Классификации биологических объектов на основе многомерного биоимпедансного анализа // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 3/4. С. 29–49.

6. Шаталова О. В., Стадниченко Н. С., Ефремов М. А. и др. Технологии биоимпедансной спектроскопии в системах поддержки принятия решений при диагностике социально значимых заболеваний // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 4. С. 148–174. DOI [10.21869/2223-1536-2023-13-4-148-174](https://doi.org/10.21869/2223-1536-2023-13-4-148-174)

7. Серебровский А. В., Корсунский Н. А., Лях А. В. и др. Мультимодальный классификатор медицинского риска на основе биоимпедансного анализа // Нейроинформатика, ее приложения и анализ данных: материалы XXXII Всерос. семинара. Красноярск: Институт вычислительного моделирования СО РАН, 2024. С. 90–100.

8. Суржикова С. Е., Шаталова О. В., Федянин В. В. Программно-аппаратный комплекс для анализа вольтамперных характеристик биоактивных точек на основе модуля L-CARD E20-10 // Прикаспийский журнал: управление и высокие технологии. 2015. № 2 (30). С. 150–161.

9. Mornsun Power. E05_S-1WR3 Series DC/DC Converter Datasheet. Mornsun, 2022. URL: <https://www.mornsun-power.com>

10. Advanced Monolithic Systems. AMS1117 Series Datasheet. AMS, 2017. URL: <https://www.advanced-monolithic.com/pdf/ds1117.pdf>

11. Патент 2834149 Российская Федерация, МПК А 61 В 5/0531, G 06 F 18/24, G 06 N 3/02. Способ определения риска рака молочной железы на основе спектроскопии биоимпеданса и с учетом анизотропии биоматериала / С. А. Филист, А. В. Серебровский, А. А. Кузьмин, О. В. Шаталова, И. А. Халин, А. В. Лях; заявитель и патентообладатель ФГБОУ ВО «Юго-Западный государственный университет». № 2024113732; заявл. 21.05.2024; опубл. 03.02.2025, Бюл. № 4.

TECHNOLOGIES OF ARTIFICIAL INTELLIGENCE AND BIOIMPEDANCE SPECTROSCOPY FOR CLASSIFICATION OF THE FUNCTIONAL STATE OF HUMAN ORGANS AND SYSTEMS

Nikita A. Korsunskiy

Olga V. Shatalova

Southwest State University

94, 50 Let Oktyabrya Str., Kursk, Russia, 305040

cor.nick2013@yandex.ru

Evgeniy A. Startsev

Voronezh State Technical University

84, 20th Anniversary of October Str., Voronezh, Russia, 394006

starcev_evgeniy@mail.ru

This paper presents the results of developing a diagnostic method for viral respiratory diseases based on bioimpedance spectroscopy and artificial intelligence algorithms. The study describes the process of informative feature extraction, the creation of a hybrid classifier, and clinical validation. The proposed methodology has demonstrated high diagnostic efficiency and comparability with traditional instrumental approaches.

Keywords: bioimpedance spectroscopy, artificial intelligence, hybrid neural network, fuzzy logic, medical decision-making

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ АНАЛИЗА ДАННЫХ АУСКУЛЬТАЦИИ НА ОСНОВЕ АРХИТЕКТУРЫ ТРАНСФОРМЕР

Лузин Владимир Витальевич

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
vvluzin_1@edu.hse.ru

Своевременная диагностика сердечно-сосудистых заболеваний является одной из ключевых задач современного здравоохранения. Аускультация сердца, будучи базовым методом скрининга, часто ограничена субъективностью интерпретации звуковых данных. В данной работе представлено описание разработки интеллектуальной системы поддержки принятия решений, реализованной в виде веб-сервиса, для автоматической классификации аудиозаписей сердечных тонов. В основе системы лежит модель глубинного обучения архитектуры трансформер – Audio Spectrogram Transformer (AST), дообученная на агрегированном наборе данных сердечных звуков. Итоговая модель достигла точности 95% на тестовой выборке, успешно различая нормальные сердечные тоны, патологические шумы и ошибочные (посторонние) аудиозаписи. Работа демонстрирует высокий потенциал современных трансформерных архитектур в решении задач медицинской диагностики и представляет прототип готового к апробации программного инструмента.

Ключевые слова: искусственный интеллект, глубинное обучение, трансформер, анализ аудио, аускультация сердца, система поддержки принятия решений, цифровая медицина

Введение. Сердечно-сосудистые заболевания (ССЗ) остаются одной из ведущих причин смертности во всем мире [1]. Аускультация сердца является фундаментальным, доступным и неинвазивным методом первичного обследования, однако ее точность напрямую зависит от опыта и слуха врача. Автоматизация этого процесса с помощью методов искусственного интеллекта (ИИ) может значительно повысить объективность и доступность первичной диагностики [2, 3].

Целью работы является разработка и оценка эффективности интеллектуальной системы для классификации аудиозаписей сердечных тонов на основе модели трансформер, а также ее реализация в виде прототипа веб-приложения для практического применения.

Исследование предметной области. Цифровая запись сердечных тонов позволяет работать с данными аускультации как с неструктурированными аудиосигналами, применяя для их анализа алгоритмы машинного обучения. Анализ существующих решений показал, что ранние работы в этой области опирались на классические методы машинного обучения [2, 3] или ранние архитектуры глубокого обучения, такие как сверточные нейронные сети [14] и рекуррентные нейронные сети (15). Эти подходы показывали хорошие результаты на очищенных

данных [13], однако их возможности могут быть ограничены при работе с зашумленными аудиозаписями разного качества. В то же время архитектура Трансформер, изначально предложенная для задач обработки естественного языка [4], продемонстрировала state-of-the-art результаты в работе с различными последовательными данными, включая аудио [4]. Ее применение для анализа сердечных тонов является новой и перспективной областью исследований. Некоторые недавние работы подтвердили высокий потенциал трансформеров для данной задачи [16]. Таким образом, на основе анализа предметной области было принято решение сфокусироваться на применении современной архитектуры Трансформер как наиболее перспективной для решения поставленной задачи.

Постановка задачи и формирование DataSet. Для обучения и тестирования модели был сформирован агрегированный набор данных из трех открытых источников, содержащий в общей сложности около 6500 аудиозаписей [5–7]. Важно отметить, что исходные данные характеризовались значительной гетерогенностью и зачастую низким качеством. Многие записи, сделанные с помощью неспециализированного оборудования (например, микрофонов смартфонов), отличались очень низкой амплитудой полезного сигнала, из-за чего тоны сердца были едва различимы. Работа с такими сложными данными, с одной стороны, позволила создать более робастную модель, способную выделять признаки даже из очень слабого сигнала, но, с другой стороны, улучшение и курирование набора данных является ключевой точкой для дальнейшего роста точности.

Данные были разделены на обучающую, валидационную и тестовую выборки в соотношении 80/10/10. Аудиозаписи были разделены на три целевых класса: «Нормальные тоны сердца», «Патологические тоны сердца» и «Ошибка / Шум». Введение последнего класса критически важно для повышения надежности системы в реальных условиях эксплуатации. В процессе предобработки не применялись методы аугментации данных, так как в задачах тонкозернистой (fine-grained) классификации они могут исказить важные диагностические признаки [8].

Архитектура модели глубинного обучения. Для решения задачи классификации была выбрана архитектура Трансформер [4], доказавшая свою высокую эффективность в улавливании долгосрочных зависимостей в последовательных данных. В качестве основной модели использована Audio Spectrogram Transformer (AST) [9]. Ключевая идея AST заключается в преобразовании аудиосигнала в мел-спектрограмму, которая затем обрабатывается архитектурой Vision Transformer (ViT) [10].

В рамках исследования проведен также эксперимент с моделью Wav2Vec2 [11], предобученной на данных человеческой речи, которая показала значительно худшие результаты. Это подтверждает гипотезу о том, что для анализа медицинских звуков предпочтительнее использовать модели, предобученные на более широком и разнообразном наборе аудиоданных. Модель AST была предобучена на датасете AudioSet [12], включающем сотни различных классов звуков. Процесс дообучения модели производился на кластере с использованием одной видеокарты NVIDIA A100.

Архитектура программного комплекса. Для практической реализации системы был разработан программный комплекс (рис. 1), состоящий из трех ос-

новных компонентов: Frontend-сервис (Streamlit), Backend-сервис (FastAPI) и Model Service. Взаимодействие между Backend и Model Service организовано асинхронно через брокер сообщений RabbitMQ. Весь комплекс контейнеризирован с помощью Docker.




Рис. 1. Высокоуровневая архитектура разработанного сервиса

Оценка качества модели. Оценка качества итоговой модели AST проводилась на отложенной тестовой выборке. Модель продемонстрировала высокую общую эффективность, достигнув общей точности (accuracy) 0.956. Столь высокий показатель во многом обусловлен способностью модели практически безошибочно идентифицировать некорректные или зашумленные аудиозаписи, отфильтровывая их от данных, пригодных для анализа.

При рассмотрении более сложной бинарной задачи – непосредственного различения классов «Норма» и «Патология» – точность составила 0.936. Модель демонстрирует высокую полноту (Recall = 0.9), успешно выявляя 90% записей с фактическими патологиями, что является критически важным для задач медицинского скрининга, где пропуск заболевания более нежелателен, чем ложноположительное срабатывание. При этом точность (Precision) составила 0.85, что указывает на сбалансированную работу модели.

Графики процесса обучения (рис. 2) демонстрируют высокую эффективность выбранного подхода. Модель AST с полным дообучением (full fine-tuning) показывает быструю сходимость, достигая плато по точности уже после второй эпохи с последующими незначительными улучшениями. Это подтверждает отсутствие явного переобучения и стабильность процесса обучения. В то же время альтернативные подходы, такие как обучение только линейного классификатора поверх «замороженной» модели AST (linear probing) и дообучение Wav2Vec2, продемонстрировали значительно более низкое итоговое качество, что подтверждает правильность выбора основной модели и стратегии ее дообучения.

Анализ кривых PR и ROC (рис. 3) подтверждает высокую разделяющую способность модели для всех классов. Идеальные показатели для класса «Ошибка / Шум» свидетельствуют о его безошибочной идентификации, в то время как высокие, хотя и неидеальные значения для классов «Норма» и «Патология» указывают на общую эффективность модели.




Рис. 2. Графики процесса обучения моделей (Loss и Accuracy)




Рис. 3. Кривые PR (Precision-Recall) и ROC для каждого класса

Матрица ошибок (рис. 4) детализирует результаты, показывая нулевое количество ошибок для класса «Ошибка / Шум». Основная часть неверных предсказаний сосредоточена между классами «Норма» и «Патология», что является ключевым фактором, ограничивающим точность в задаче бинарной классификации.




Рис. 4. Матрица ошибок итоговой модели на тестовой выборке

Практическая реализация: веб-приложение. Разработанный прототип веб-приложения (рис. 5) предоставляет интуитивно понятный интерфейс для загрузки аудиофайла, его прослушивания и выделения нужного сегмента, получения результата классификации и просмотра истории. Важно подчеркнуть, что данное приложение позиционируется как система поддержки принятия решений и не предназначено для постановки окончательного диагноза.




Рис. 5. Интерфейс веб-приложения с примером результата анализа

Заключение. В результате исследования была разработана интеллектуальная система для автоматической классификации аудиозаписей аускультации сердца, реализованная в виде веб-сервиса.

В основе разработанной системы лежит модель глубинного обучения архитектуры Audio Spectrogram Transformer (AST), дообученная для классификации аудиозаписей на три класса: нормальные сердечные тоны, патологические шумы и ошибки записи. Проведенная оценка качества на отложенной тестовой выборке продемонстрировала высокую эффективность подхода, достигнув общей точности в 95%. Применение выбранной трансформерной архитектуры позволяет проводить автоматический скрининг аудиозаписей сердца. Данный подход может быть использован для разработки аналогичных систем в других областях медицинской аудиодиагностики, например для анализа звуков легких.

Исходя из полученных результатов, система демонстрирует корректную работу и высокий потенциал для практического применения в качестве инструмента поддержки принятия врачебных решений. Она может быть полезна врачам общей практики для предварительной оценки состояния пациента, а также в рамках развития телемедицинских сервисов.

Поддержка исследований. Работы ведутся в рамках госзадания EZID-2025-0003 «Разработка технологий снижения смертности населения от сердечно-сосудистых заболеваний в целях их применения в системе здравоохранения (диспансеризация) на основе ранней диагностики, профилактики и телемедицинской оценки реабилитационных мероприятий» № 1024022200061-2-3.1.4; 3.2.25; 1.2.1».

Библиографический список

1. Cardiovascular diseases // World Health Organization. URL: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (дата обращения: 10.09.2025).
2. Давыдов А. В., Жусупова А. К., Салыкова О. С. Обнаружение признаков болезни сердца с использованием методов машинного обучения // Вестник науки. 2022. Т. 2, № 5 (50). С. 78–86.
3. Кузин Д. А., Стаценко Л. Г., Анисимов П. Н., Смирнова М. М. Применение методов машинного обучения для классификации акустических сигналов по спектральным характеристикам // Известия СПбГЭТУ ЛЭТИ. 2021. № 3. С. 48–54.
4. Vaswani A. et al. Attention is all you need // Advances in neural information processing systems. 2017. Vol. 30.
5. Heart Sound Dataset // Kaggle. URL: <https://www.kaggle.com/datasets/biswajitpatra/heart-sound-dataset/> (дата обращения: 22.03.2025).
6. Heartbeat Sounds // Kaggle. URL: <https://www.kaggle.com/datasets/kinguistics/heartbeat-sounds/> (дата обращения: 22.03.2025).
7. Heart sound database // Kaggle. URL: <https://www.kaggle.com/datasets/swapnilpanda/heart-sound-database/> (дата обращения: 22.03.2025).
8. Yang Z. et al. Learning to navigate for fine-grained classification // Proceedings of the European conference on computer vision (ECCV). 2018. P. 420–435.
9. Gong Y., Chung Y. A., Glass J. Ast: Audio spectrogram transformer // arXiv preprint arXiv:2104.01778. 2021.
10. Dosovitskiy A. et al. An image is worth 16x16 words: Transformers for image recognition at scale // arXiv preprint arXiv:2010.11929. 2020.
11. Baeveski A. et al. wav2vec 2.0: A framework for self-supervised learning of speech representations // Advances in Neural Information Processing Systems. 2020. Vol. 33. P. 12449–12460.
12. Gemmeke J. F. et al. Audio set: An ontology and human-labeled dataset for audio events // 2017 IEEE international conference on acoustics, speech and signal processing (ICASSP). IEEE, 2017. P. 776–780.
13. Taneja A. et al. Heart audio Classification using deep learning // 2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA). IEEE, 2020. P. 485–488.
14. O'shea K., Nash R. An introduction to convolutional neural networks // arXiv preprint arXiv:1511.08458. 2015.
15. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network // Physica D: Nonlinear Phenomena. 2020. Vol. 404. Article 132306.
16. Liu Z. et al. Heart sound classification based on bispectrum features and vision transformer mode // Alexandria Engineering Journal. 2023. Vol. 85. P. 49–59.

INTELLIGENT DECISION SUPPORT SYSTEM FOR AUSCULTATION DATA ANALYSIS BASED ON A TRANSFORMER ARCHITECTURE

Vladimir V. Luzin

HSE University

38, Studencheskaya Str., Perm, Russia, 614070

vvluzin_1@edu.hse.ru

Keywords: artificial intelligence, deep learning, Transformer, audio analysis, heart sound analysis, decision support system, digital medicine

МНОГООКОННОЕ СКАНИРОВАНИЕ В ЗАДАЧАХ ВЫДЕЛЕНИЯ ОБЛАСТЕЙ ИНТЕРЕСА НА ЭНДОСКОПИЧЕСКИХ УЛЬТРАЗВУКОВЫХ ИЗОБРАЖЕНИЯХ

Кондрашов Дмитрий Сергеевич

Коробков Сергей Васильевич

Кузьмин Александр Алексеевич

Филист Сергей Алексеевич

Юго-Западный государственный университет
305000, Россия, г. Курск, ул. 50 лет Октября, 94
SFilist@gmail.com

В статье представлен метод и алгоритм отбора релевантных кадров из видеоряда эндоскопических ультразвуковых изображений. Посредством текстурного анализа областей снимка, выделенных первым и вторым окнами, формируют пространство информативных признаков для нейросетевого классификатора пикселя, определенного первым окном.

Ключевые слова: семантическая сегментация, вложенные динамические окна, текстурный анализ, нейросетевой классификатор

Введение. В сообществе эндоскопистов признается, что некоторые анатомические структуры практически невозможно идентифицировать на статическом изображении. Это связано с трудностью замены текущего кадра в локальном контексте, когда для однозначной классификации частей анатомического объекта необходимы различные внешние визуальные маркеры. В частности, дифференциации тела поджелудочной железы (ПЖ) от хвоста сложно различить по отдельности. Тем не менее близость селезенки или почки указывает на хвостовую часть ПЖ. При этом окружающие структуры, такие как общий желчный проток или брыжеечные сосуды, также являются отличительными маркерами. Однако поскольку УЗИ позволяет получить только двумерное поперечное сечение за один кадр, для сбора всей этой информации для окончательной классификации специалистами-людьми может потребоваться несколько последовательных кадров, соответствующих временному контексту. Более того, ручное описание очагов поражения на снимках УЗИ для оценки их размера отнимает много времени и приводит к разным результатам из-за плохого согласия между наблюдателями.

В связи с изложенным в области медицинской визуализации в настоящее время начали широко применяться компьютерные методы обработки изображений УЗИ, в том числе с использованием моделей машинного (МО) и глубокого обучения (ГО), которые разрабатываются для извлечения сложных признаков из данных изображений [1].

Методы. Метод основан на использовании гибридных технологий и реализуется в два этапа. На первом этапе снимок УЗИ декомпозируется на несколько уровней, каждый из которых состоит из изображений-потомков. Сегмент верхнего

уровня делится на четыре дочерних сегмента, и каждый из них классифицируется как «ROI» или «НЕ ROI» в зависимости от характеристик объекта. Только сегменты, отнесенные к классу «ROI», подвергаются дальнейшей декомпозиции. Если сегмент определяется как «НЕ ROI», анализ переходит к следующему сегменту того же уровня [3–7].

На рис. 1 показан пример декомпозиции УЗИ-изображения ПЖ: на первом уровне из четырех сегментов лишь два (№ 1 и № 2) подвергаются дальнейшей декомпозиции (рис. 1,а). Рисунок 1,б демонстрирует деление сегмента № 2 на втором уровне [8, 9]. После декомпозиции сегмента проводится повторная проверка принадлежности сегментов второго уровня к классу «ROI». Далее формируется набор ROI. При необходимости они могут быть объединены: если два или более сегмента имеют общую границу, она игнорируется и ROI-область увеличивается. Процесс объединения представлен на рис. 1,в и 1,г [8].




Рис. 1. Пример сегментации изображения:

а) – на первом уровне декомпозиции; б) – сегмент № 2 на втором уровне [7, 8]

На втором этапе гибридного метода используется обучаемый классификатор. Для обучаемого классификатора разработан метод формирования информативных признаков (ИП), который основан на сканировании эхографических текстур при помощи двух динамических окон различного масштаба. На рис. 2 проиллюстрировано схематичное представление работы этого метода [9–12].



Рис. 2. Иллюстрация метода формирования информативных признаков для обучаемого классификатора

Двойное сканирование снимка видеоряда состоит в следующем. Первое окно перемещается внутри второго окна, сканируя область, заданную вторым окном, при этом на каждом шаге его перемещения рассчитываются статистические показатели: мода, среднее значение и среднее квадратичное отклонение (СКО). Они позволяют количественно оценить однородность структуры, вариабельность плотности тканей и показатели экзогенности. Второе окно определяет область сканирования в пределах всего кадра и определяется на первом этапе гибридного метода. Для второго окна также рассчитываются статистические показатели, аналогичные первому окну. На каждом шаге перемещения первого окна применяется нейросетевой классификатор (НК), который принимает решение о принадлежности пикселя кадра, соответствующего координате первого окна, к релевантному классу. Если результат на выходе НК превышает пороговое значение, то его результат записывается в накопительный массив. В результате анализа кадра двумя динамическими окнами формируется тепловая карта, которая накладывается на изображение ПЖ и далее анализируется врачом-специалистом.

Полученные данные используются для формирования вектора информативных признаков (ИП), представленного выражением:

$$F = [Моda_1, СКО_1, Среднее_1, Моda_2, СКО_2, Среднее_2], \quad (1)$$

где $Моda_1, СКО_1, Среднее_1$ – мода, среднее квадратическое отклонение и среднее значение динамического окна 1; $Моda_2, СКО_2, Среднее_2$ – мода, среднее квадратическое отклонение и среднее значение динамического окна 2.

Сформированный вектор ИП подается на вход нейронной сети (NET). Классификатор анализирует входные параметры и принимает решение о принадлежности пикселя к ROI. После завершения работы нейронной сети формируется тепловая карта, которая далее анализируется лицом, принимающим решение (врачом) [12, 13].

В результате анализа отобранных эхографических текстур рассчитан размер первого динамического окна, который составил 150×126 пикселей ($3,95 \times 3,34$ см). Размер второго окна определялся с использованием программного обеспечения, реализующего метод каскадной сегментации, основанный на критерии однородности. Оптимальный размер окна определялся на основе анализа однородных структур, обнаруженных на всех изображениях.

Размеры структур при панкреатите варьируются от $2,65 \times 3,52$ до $4,84 \times 3,18$ см, что в среднем меньше, чем у онкологических образований, но также демонстрирует значительный разброс. Увеличение размеров ПЖ при воспалительных процессах хотя и наблюдается, но выражено в меньшей степени.

Эхотекстуры артерий характеризуются размерами, находящимися в диапазоне от $2,94 \times 2,01$ до $4,58 \times 3,57$ см. Вариации размеров, как правило, меньше, чем в случае онкологических образований, но частично перекрываются с размерами, наблюдаемыми при панкреатите. Более узкий диапазон изменений размеров позволяет отличать их от патологических изменений в ПЖ. Таким образом, анализ размеров эхографических структур позволяет определить характер патологических изменений: опухолевые процессы, как правило, характеризуются увеличен-

ными размерами, панкреатит проявляется структурами среднего размера, в то время как артерии обладают относительно меньшими и более однородными параметрами.

Программное обеспечение семантической сегментации релевантных кадров для обучения нейросетевых классификаторов. С опорой на гибридный метод разработано программное обеспечение анализа и выбора релевантных кадров из видеоряда УЗИ ПЖ. На первом этапе осуществляется инициализация программы и загружается кадр УЗИ ПЖ размером $S = N \times M$. Затем осуществляется проверка условия необходимости предварительной обработки данных. В случае положительного результата выполняется процедура предобработки кадра, в противном случае данный этап пропускается.

На следующем этапе задаются размеры двух динамических окон: второе окно $m1 \times m2$ и первое окно $n1 \times n2$. Второе окно определяет область локального анализа и перемещается по изображению горизонтально и вертикально с требуемым шагом, заданным пользователем. При каждом перемещении второго окна осуществляется выделение соответствующего фрагмента и рассчитываются статистические или спектральные характеристики, которые используются для построения вектора признаков $\{\psi 2_{i,j}\}$ [14, 15].

Далее осуществляется перемещение первого окна внутри второго окна. В результате такого перемещения осуществляется детальное исследование всей площади второго окна, в ходе которого из изображения извлекаются меньшие по размеру участки. Для каждого из них также вычисляются статистические характеристики и формируется вектор признаков $\{\psi 1_{k,l}\}$.

Полученные признаки двух уровней – второго и первого окон – объединяются в векторе ИП и передаются на вход НК. Нейронная сеть осуществляет анализ ИП и выдает вероятностное значение принадлежности пикселя, определяющего координаты окна 1, к классу ROI, т.е. осуществляется функция классификации. Результаты классификации записываются в массив значений, который накапливает количество положительных результатов, соответствующих классу ROI. После завершения анализа всех окон формируется итоговая тепловая карта изображения ПЖ.

Генерация тепловой карты осуществляется путем агрегации значений массива с последующей нормализацией по количеству проходов пикселей. В результате получается массив, содержащий значения в диапазоне от 0 до 1, которые визуализируются с помощью цветовой шкалы, где минимальному значению (0) соответствует синий цвет, а максимальному (1) – красный. После вывода тепловой карты на изображение ЭУС ПЖ осуществляется ее анализ специалистом и принимается решение о релевантности кадра.

Заключение. Разработан гибридный метод и алгоритм семантической сегментации кадров из видеоряда эндоскопических ультразвуковых изображений. В основу метода положен анализ кадров с помощью двух динамических окон различного масштаба. Первое окно сканирует область, выделенную вторым окном, а второе окно определяет область сканирования в пределах всего кадра, что позволяет учитывать пространственные особенности эндоскопического ультра-

звукового изображения поджелудочной железы. Внутри каждого окна производится расчет статистических показателей: моды, среднего значения и среднеквадратичного отклонения. На каждом шаге перемещения первого окна применяется нейросетевой классификатор, который принимает решение о принадлежности пикселя кадра, соответствующего координате первого окна, к релевантному классу и формирует тепловую карту положительных результатов, относящихся к классу «Область интереса». После завершения анализа всех окон формируется итоговая тепловая карта на эндоскопическом ультразвуковом изображении поджелудочной железы. По анализу тепловой карты на эндоскопическом ультразвуковом изображении поджелудочной железы специалист относит его к релевантному классу. По результатам экспериментальных исследований точность разработанного метода для обнаружения релевантных кадров составила не ниже 96%.

Библиографический список

1. Egger J., Schmalstieg D., Bettac L. et al. In-depth Assessment of an Interactive Graph-based Approach for the Segmentation for Pancreatic Metastasis in Ultrasound Acquisitions of the Liver with two Specialists in Internal Medicine // 2017 Biomedical Engineering International Conference (BMEiCON-2017).
2. Bahrami N., Rezatofghi S. H., Adeli A. M., Setarehdan S. K. Boundary delineation for hepatic hemangioma in ultrasound images // Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference. 2011. P. 7989–7992. DOI [10.1109/IEMBS.2011.6091970](https://doi.org/10.1109/IEMBS.2011.6091970)
3. Dabagov A. R., Gorbunov V. A., Filist S. A. et al. An automated system for classification of radiographs of the breast // Biomedical Engineering. 2020. Vol. 53, no. 6. P. 425–428. DOI [10.1007/s10527-020-09957-7](https://doi.org/10.1007/s10527-020-09957-7)
4. Dabagov A. R., Tomakova R. A., Alekseev V. A. et al. Automated analysis of x-ray images using transparency masks // Journal of Physics: Conference Series: 10th International Conference on High-Performance Computing Systems and Technologies in Scientific Research, Automation of Control and Production (HPCST 2020) (15–16 May 2020). Volgograd: IOP Publ. Ltd, 2020. Article 012011. DOI [10.1088/1742-6596/1615/1/012011](https://doi.org/10.1088/1742-6596/1615/1/012011)
5. Tomakova R. A., Egorov I. S., Lyubitsky N. A., Kondrashov D. S. Intelligent system for processing and analysis of mammograms // Journal of Physics: Conference Series: 2nd International Scientific Conference on Artificial Intelligence and Digital Technologies in Technical Systems 2021 (AIDTTS II 2021) (06–07 May 2021). Volgograd: IOP Publ. Ltd, 2021. Article 012030. DOI [10.1088/1742-6596/2060/1/012030](https://doi.org/10.1088/1742-6596/2060/1/012030)
6. Filist S. A., Kondrashov D. S., Kuz'min A. A. et al. Classification of medical images based on the spectra of local windows // Biomedical Engineering. 2024. Vol. 57, no. 5. P. 321–324. DOI [10.1007/s10527-023-10324-5](https://doi.org/10.1007/s10527-023-10324-5)
7. Филист С. А., Дабагов А. Р., Томакова Р. А. и др. Метод каскадной сегментации рентгенограмм молочной железы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 1. С. 49–61. URL: https://swsu.ru/izvestiya/seriesivt/archiv/1_2019.pdf
8. Филист С. А., Дабагов А. Р., Томакова Р. А. и др. Многослойные морфологические операторы для сегментации сложнотруктурируемых растровых полутоновых изображений // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 3. С. 44–63. URL: https://swsu.ru/izvestiya/seriesivt/archiv/3_2019.pdf
9. Дабагов А. Р., Малютина И. А., Кондрашов Д. С. и др. Автоматизированная система для классификации заболеваний молочной железы по рентгеновским маммографическим снимкам // Прикаспийский журнал: управление и высокие технологии. 2019. № 4. С. 10–24. URL: [https://hi-tech.asu.edu.ru/files/4\(48\)/10-24.pdf](https://hi-tech.asu.edu.ru/files/4(48)/10-24.pdf)
10. Филист С. А., Шевцов М. В., Белозеров В. А. и др. Автоматизированная система для классификации снимков видеопотоков // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2021. Т. 11, № 4. С. 85–105. URL: https://swsu.ru/izvestiya/seriesivt/archiv/4_2021.pdf

11. Филист С. А., Кондрашов Д. С., Сухомлинов А. Ю. и др. Автоматизированная система классификации снимков УЗИ поджелудочной железы на основе метода посегментного спектрального анализа // Моделирование, оптимизация и информационные технологии. 2023. Т. 11, № 4. С. 1–19. DOI 10.26102/2310-6018/2023.40.1.021
12. Кузьмин А. А., Сухомлинов А. Ю., Аль-Дарраджи Ч. Х., Томакова Р. А. Автоматизированная классификация абдоминальных ультразвуковых изображений поджелудочной железы на основе спектрального представления контуров ее границы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 67–87. DOI 10.21869/2223-1536-2024-14-1-67-87
13. Kuzmin A., Al-Darraj C., Sukhomlinov A., Filist S. Two-Dimensional Walsh Spectral Transform in Problems of Automated Analysis of Ultrasound Images // Creativity in Intelligent Technologies and Data Science. 2023. Vol. 1909. P. 467–477. DOI 10.1007/978-3-031-44615-3_32
14. Кузьмин А. А., Сухомлинов А. Ю., Филист С. А., Жилин И. А. Метод двойного спектрального сканирования при определении границ артерий на снимках коронарной ангиографии // Вестник Казанского государственного энергетического университета. 2024. Т. 16, № 4 (64). С. 13–24.
15. Кузьмин А. А., Сухомлинов А. Ю., Жилин И. А., Филист С. А. и др. Моделирование рентгеноконтрастных ангиографических изображений для определения параметров сосудов методом двойного спектрального сканирования // Моделирование, оптимизация и информационные технологии. 2025. Т. 13, № 2. С. 1–21. DOI 10.26102/2310-6018/2025.49.2.011

MULTI-WINDOW SCANNING FOR THE PROBLEMS OF SELECTION OF REGIONS OF INTEREST IN ENDOSCOPIC ULTRASONIC IMAGES

Dmitry S. Kondrashov

Sergey V. Korobkov

Alexander A. Kuzmin

Sergey A. Filist

Southwestern State University,
94, 50 years of October Str., Kursk, Russia, 305000
SFilist@gmail.com

A hybrid method and algorithm for semantic segmentation of frames from video sequences of endoscopic ultrasound images of the pancreas have been developed. The method is based on frame analysis using two dynamic windows of different sizes. The first window scans the area selected by the second window, while the second window defines the scanning area within the entire frame, allowing for the spatial characteristics of the endoscopic ultrasound image of the pancreas to be taken into account. Within each window, statistical parameters are calculated: mode, mean, and standard deviation. At each step of the first window's movement, a neural network classifier is used to determine whether the frame pixel corresponding to the first window's coordinate belongs to the relevant class and generates a heat map of positive results related to the "Region of Interest" class. After completing the analysis of all windows, a final heat map of the endoscopic ultrasound image of the pancreas is generated. Based on heat map analysis of an endoscopic ultrasound image of the pancreas, a specialist classifies it as relevant. Experimental studies showed that the accuracy of the developed method for detecting relevant frames was at least 96%.

Keywords: semantic segmentation, nested dynamic windows, texture analysis, neural network classifier

О ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ МЕТОДОВ И АЛГОРИТМОВ ИНТЕЛЛЕКТУАЛЬНОЙ ОБРАБОТКИ ВИДЕОДАННЫХ К ЗАДАЧЕ БЕСКОНТАКТНОГО ОПРЕДЕЛЕНИЯ УРОВНЯ АРТЕРИАЛЬНОГО ДАВЛЕНИЯ

Челышев Эдуард Артурович

Национальный исследовательский университет «МЭИ»
111250, Россия, г. Москва, ул. Красноказарменная, д. 14, стр. 1
chel.ed@yandex.ru

Раскатова Марина Викторовна

Национальный исследовательский университет «МЭИ»
111250, Россия, г. Москва, ул. Красноказарменная, д. 14, стр. 1
marina@raskatova.ru

В статье представлены обзор, анализ и систематизация научных публикаций, посвященных применению методов и алгоритмов интеллектуальной обработки видеоданных к задаче бесконтактного определения уровня артериального давления. Проанализированы использованные в работах подходы, объем использованных данных и качество полученных решений на основе ряда метрик. Выявлены существующие в данной предметной области проблемы и ограничения.

Ключевые слова: артериальное давление, видеоданные, нейронная сеть, дистанционная фотоплетизмография

Введение. Артериальное давление является одним из ключевых показателей здоровья человека. Гипертония, или стойкое повышение артериального давления, представляет серьезную проблему как для здоровья отдельного человека, так и для общественного здравоохранения в целом. По данным Всемирной организации здравоохранения, гипертония является одной из ведущих причин преждевременной смерти, при этом данным заболеванием страдает около 40% взрослого населения планеты [1]. Данная статистика подчеркивает актуальность исследований в данной области.

Известно, что артериальное давление характеризуется двумя показателями: верхним (систолическим) и нижним (диастолическим) давлением [2]. Традиционным способом измерения артериального давления является манжеточный метод, основанный на применении специального устройства для измерения артериального давления – тонометра. Однако такой метод неудобен в использовании в связи с необходимостью всегда иметь под рукой специализированное устройство [3].

Решить данную проблему призваны носимые электронные устройства с функцией измерения артериального давления. Измерение артериального давления в них выполняется за счет анализа пульсовых волн кровотока, а именно на основе их времени распространения и формы. В частности, большой популярностью пользуется фотоплетизмографический метод, основанный на использовании инфракрасного излучателя, направленного на кожу человека, с дальнейшим анализом отраженной от поверхности кожи световой волны [4].

В последние годы наблюдается значительный рост интереса к применению методов интеллектуальной обработки видеоданных в медицине, в частности для бесконтактного мониторинга физиологических параметров человека. Большой теоретический и практический интерес представляет применение дистанционной фотоплетизмографии. Данный метод подразумевает видеофиксацию участка поверхности кожи с дальнейшим анализом видеоряда. Фактически данный метод совмещает в себе подход, принятый в традиционной фотоплетизмографии (анализ отраженного света) и методы и алгоритмы обработки видеоданных [5].

В работе представлен обзор и сравнительный анализ работ, посвященных использованию методов и алгоритмов интеллектуальной обработки видеоданных в задаче определения уровня артериального давления.

Сравнительный анализ работ по теме. В научных публикациях на данную тематику используются различные нейросетевые модели. Так, авторы работ [6] и [7] опираются на сложные архитектуры нейронных сетей, включая ResNet, Bi-LSTM и Vision Transformer, а в работах [8] и [9] за основу берется архитектура U-Net. Кроме того, стоит отметить, что размеры использованных в работах наборов данных сильно отличаются друг от друга и варьируются в диапазоне от десятков до тысяч объектов. В табл. 1 представлено сравнение анализируемых работ по критериям использованной методологии и размера набора данных.

Таблица 1

Сравнение анализируемых работ

Работа	Методология	Размер набора данных
[6]	Пространственно-временные карты и искусственная нейронная сеть, объединяющая архитектуру сетей ResNet и Bi-LSTM	132
[7]	Сверточная нейронная сеть, Vision Transformer и многослойный персептрон	143
[8]	U-Net, усовершенствованная техниками сглаживания распределения меток	200
[9]	U-Net с применением трансферного обучения (transfer learning)	7 852

В работе [6] исходные видеоданные прошли обработку, включающую обнаружение региона интереса, аугментацию данных и сегментирование (разделение видео на короткие пересекающиеся фрагменты). Для улучшения качества видео использовалось модифицированное цветовое пространство YUV.

Была разработана искусственная нейронная сеть, основанная на архитектурах ResNet и Bi-LSTM. Результаты, достигнутые предложенной искусственной нейронной сетью на тестовой выборке, представлены в табл. 2.

Таблица 2

Результаты на тестовых наборах для [6]

Тестовый набор данных	Тип давления	SD, мм рт. ст.	RMSE, мм рт. ст.	MAE, мм рт. ст.
Первый	систолическое	16.02	16.55	12.35
	диастолическое	11.98	12.22	9.54
Второй	систолическое	9.81	9.94	8.07
	диастолическое	8.28	8.45	6.78

В работе [7] предложена гибридная модель, обучение которой проводилось не только на данных дистанционной фотоплетизмографии, но и с учетом общих сведений о пациенте. Гибридная модель включает в себя сверточную нейронную сеть, дополненную сетью Vision Transformer для анализа сигнала дистанционной фотоплетизмографии, и многослойные перцептроны для анализа общих сведений и расчета выхода модели в целом. В данной работе наилучшим результатом являлось значение $MAE = 11.35$ мм. рт. ст.

В работе [8] для прогнозирования использовалась искусственная нейронная сеть, основанная на архитектуре U-Net, усовершенствованная техниками сглаживания распределения меток для борьбы с дисбалансом классов. Результаты, достигнутые на тестовой выборке, представлены в табл. 3.

Таблица 3

Результаты на тестовых наборах для [8]

Тип давления	MAPE, %	SD, мм рт. ст.
Диастолическое	7.52	3.22
Систолическое	9.52	2.69

В работе [9] предлагается нейросетевая модель, для обучения которой применялось трансферное обучение (*англ.* transfer learning). Вначале нейронная сеть была обучена на данных контактной фотоплетизмографии, а затем ее веса были заморожены, а к самой нейронной сети был добавлен Inception Residual Block, который представляет собой архитектурный модуль нейронных сетей, сочетающий идею параллельных сверток разного масштаба (Inception) с остаточными связями (Residual), за счет чего возможно одновременно извлекать локальные и глобальные признаки без потери информации [10].

Предложенное решение показало на данных дистанционной фотоплетизмографии следующие значения средней абсолютной ошибки для диастолического и систолического давления соответственно: 4.43 и 6.9 мм рт. ст. Однако авторы отмечают, что использованный набор данных был собран на малом количестве испытуемых и не может считаться достаточно репрезентативным для данной задачи.

Отдельно выделяется работа [11], посвященная не столько разработке интеллектуальных методов оценки уровня артериального давления, сколько сравнительному анализу качества решения задачи определения уровня артериального давления на данных, получаемых в диапазоне видимого света и в ближнем инфракрасном диапазоне. В данной работе статистически достоверных различий между двумя сравниваемыми подходами выявлено не было.

Заключение. Проведенный обзор продемонстрировал, что методы интеллектуальной обработки видеоданных обладают высоким потенциалом в задаче бесконтактного определения уровня артериального давления. Использование современных нейросетевых архитектур, а также применение продвинутых методов обучения по прецедентам позволяют достичь приемлемых результатов при решении рассматриваемой задачи.

Однако, несмотря на достигнутые результаты, требуется доработка существующих методов с целью повышения точности оценки уровня артериального

давления. Кроме того, важно учитывать, что в ряде исследований использовались недостаточно репрезентативные наборы данных, поэтому требуется верификация предлагаемых в данных работах методов на наборах данных большего объема.

Тем не менее представленные результаты подтверждают перспективность развития технологий дистанционной фотоплетизмографии и интеллектуальной обработки видеоданных для создания систем мониторинга артериального давления.

Библиографический список

1. World Health Organization (WHO). Hypertension. URL: <https://www.who.int/news-room/factsheets/detail/hypertension>
2. Desai A. N. High blood pressure // JAMA. 2020. Vol. 324, no. 12. P. 1254–1255.
3. Noh S. A. et al. History and evolution of blood pressure measurement // Clinical Hypertension. 2024. Vol. 30, no. 1. P. 9. DOI 10.1186/s40885-024-00268-7
4. P.-K. Man et al. Blood pressure measurement: from cuff-based to contactless monitoring // Healthcare. 2022. Vol. 10. Article 2113. DOI 10.3390/healthcare10102113
5. Fedorovich A. A., Drapkina O. M., Pronko K. N., Sinopalnikov V. I., Zemskov V. M. Telemonitoring of capillary blood flow in the human skin: new opportunities and prospects // Clinical Practice. 2018. Vol. 15, no. 2. P. 561–567.
6. Chen Y., Zhuang J., Li B., Zhang Y., Zheng X. Remote blood pressure estimation via the spatio-temporal mapping of facial videos // Sensors. 2023. Vol. 23. Article 2963. DOI 10.3390/s23062963
7. Curran T. et al. Estimating Blood Pressure with a Camera: An Exploratory Study of Ambulatory Patients with Cardiovascular Disease // arXiv:2503.00890v1. 2025. 19 p. URL: <https://arxiv.org/pdf/2503.00890>
8. Tan S. et al. Remote Photoplethysmography Technology for Blood Pressure and Hemoglobin Level Assessment in the Preoperative Assessment Setting: Algorithm Development Study // JMIR Form Res. 2025. Vol. 9. Article e60455. 14 p. URL: <https://formative.jmir.org/2025/1/e60455>
9. Kim S., Lim H., Baek J., Lee E.C. RGB Camera-Based Blood Pressure Measurement Using U-NetBasic Generative Model // Electronics. 2023. Vol. 12. Article 3771. 14 p. DOI 10.3390/electronics12183771
10. Szegedy C., Ioffe S., Vanhoucke V., Alemi A. A. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning // arXiv:1602.07261. 2016. 12 p. URL: <https://arxiv.org/abs/1602.07261>
11. Kawasaki S. et al. Performance evaluation of blood pressure estimation using an RGB-NIR camera // Artif Life Robotics. 2025. Vol. 30. P. 484–492. DOI <https://doi.org/10.1007/s10015-025-01015-3>

ON THE POSSIBILITY OF APPLYING METHODS AND ALGORITHMS FOR VIDEO DATA PROCESSING TO THE PROBLEM OF CONTACTLESS BLOOD PRESSURE ESTIMATION

Eduard A. Chelyshev

National Research University «Moscow Power Engineering Institute»
Bldg 1, 14, Krasnokazarmennaya Str., Moscow, Russia, 111250
chel.ed@yandex.ru

Marina V. Raskatova

National Research University «Moscow Power Engineering Institute»
Bldg 1, 14, Krasnokazarmennaya Str., Moscow, Russia, 111250
marina@raskatova.ru

The article presents a review, analysis, and systematization of scientific publications devoted to the application of methods and algorithms of intelligent video data processing to the task of contactless blood pressure estimation. The approaches used in the studies, the size of the datasets, and the quality of the obtained solutions based on a number of metrics are analyzed. Existing problems and limitations in this research domain are identified.

Keywords: blood pressure, video data, neural network, remote photoplethysmography

ПЛАТФОРМА БИОГЕНОМ: ИНТЕЛЛЕКТУАЛЬНЫЙ ПОМОЩНИК В МОНИТОРИНГЕ ЗДОРОВОГО ПИТАНИЯ

Чуприна Светлана Игоревна

Пермский государственный гуманитарно-педагогический университет
614990, Россия, г. Пермь, ул. Сибирская, 24
chuprinas@inbox.ru

Дубасов Алексей Николаевич

ООО «БИОГЕНОМ»
614990, Россия, г. Пермь, ул. Николая Островского, 93
dubasov@biogenom.ru

Постаногов Игорь Сергеевич

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

Гимашева Ксения Вадимовна

ООО «БИОГЕНОМ»
614990, Россия, г. Пермь, ул. Николая Островского, 93
gimashevaksusha1@gmail.com

В статье представлено описание концептуальных и технологических аспектов разработки одного из сервисов, входящих в состав цифровой платформы ООО «БИОГЕНОМ», направленной на решение широкого спектра задач в области здоровьесбережения в соответствии с современными принципами 4П-медицины. Сервис «Диагностика здоровья» представляет собой мобильное приложение, выполняющее роль интеллектуального помощника в мониторинге здорового питания. Технологической основой разработки является интеграция методов и средств онтологического инжиниринга, генеративного искусственного интеллекта и традиционных технологий баз данных.

Ключевые слова: 4П-медицина, мониторинг здорового питания, интеллектуальный помощник, онтологический инжиниринг, генеративный ИИ, оценка рисков здоровью

Введение. Искусственный интеллект (ИИ) в медицине имеет огромный потенциал для улучшения качества медицинской помощи, но сталкивается с рядом критических замечаний и ограничений, часть из которых будет рассмотрена далее. Это в полной мере относится и к такому направлению биомедицины, как здоровьесбережение, где значительную роль играют методы и средства учета внешних факторов и образа жизни пациента, в частности его рацион питания.

В настоящее время как в России, так и за рубежом имеется множество сервисов по типу ИИ-помощников (ИИ-ассистентов), способных за «считанные секунды» составить для пользователя персонализированное меню посредством генерации планов питания, которые учитывают его вкусовые предпочтения, требования диеты и время приема пищи. Чаще всего технологической основой реализации таких ИИ-помощников в области здорового питания являются методы машинного

обучения и в основном используются методы генеративного ИИ, основанные на применении предобученных больших языковых моделей (LLM – Large Language Model), способных анализировать и генерировать тексты на естественном языке любой тематической направленности.

Практически на той же технологической основе реализованы ИИ-помощники, позволяющие выявлять дефицит макро- и микронутриентов в ежедневном питании человека, оценить риски здоровью и предложить рекомендации в соответствии с выявленными рисками. Однако доступные российскому пользователю отечественные и зарубежные сервисы, основанные на технологиях машинного обучения, не реализуют в полной мере принципы 4П-медицины и в большей степени ориентированы на «диагноз-центрированную» модель здравоохранения. Между тем, как отмечается в [1], еще 20 лет назад за рубежом была признана необходимость изменения парадигмы в оценке последствий для индивидуального и популяционного здоровья неблагоприятных факторов среды и образа жизни с переходом от «болезнь-специфичных» к «пациент-центричным» методам субъективной оценки человеком своего здоровья.

Реализация принципов 4П-медицины легла в основу разработки сервисов цифровой платформы Biogenom. Статья посвящена описанию разработки одного из таких сервисов – мобильного приложения «Диагностика здоровья».

Концептуальные и технологические аспекты разработки интеллектуального помощника в мониторинге здорового питания. Мобильное приложение Biogenom является официальным приложением в составе национальной цифровой экосистемы персонализированного управления здоровьем Союза организаций и специалистов в сфере управления здоровьем «Здоровье Здоровых» (союзздоровьездоровых.рф). Так как описываемое приложение выполняет роль интеллектуального помощника и ориентировано на широкий круг пользователей с целью привлечения их к самостоятельному управлению здоровым питанием, то в названии сервиса под «диагностикой» понимается диагностика в широком смысле этого слова как процесс распознавания и оценки свойств, особенностей и состояний некоторого объекта / субъекта, в нашем случае – самого человека. Процесс диагностики заключается в целенаправленном исследовании рациона питания человека посредством разработанных экспертным сообществом опросников, интерпретации полученных результатов на основе базы знаний системы и их обобщения в виде заключения (диагноза), которое включает в себя оценку рисков здоровью и персонализированные рекомендации по нормализации макро- и микронутриентного состава питания. Это толкование, естественно, не исключает из числа пользователей приложения нутрициологов, врачей-диетологов и других медицинских специалистов, работающих в том числе в организациях курортной, восстановительной и превентивной медицины. Врачи при постановке уже медицинского диагноза могут использовать приложение Biogenom как помощника в оценке рисков здоровью на основании интеллектуального анализа данных его специализированных опросников.

Отличительной особенностью сервисов цифровой платформы Biogenom, включая сервис «Диагностика здоровья», является ориентация на реализацию всех принципов 4П-медицины. В настоящее время 4П-медицина считается одним

из важнейших направлений стратегического развития здравоохранения в России, призванным преодолеть ограничения современной «диагноз-центрированной» организационной модели здравоохранения в борьбе в том числе и с возрастзависимыми заболеваниями [2, 3]. Как известно, к основным принципам 4П-медицины относят персонализацию (индивидуальный подход к каждому пациенту и выявление индивидуальных паттернов симптомов заболеваний), предикцию (создание вероятностного прогноза здоровья на основе выявления ранних изменений в состоянии здоровья конкретного человека задолго до развития клинически развернутых заболеваний), превентивность (предотвращение развития заболеваний за счет оценки динамики показателей состояния здоровья персоны на фоне профилактических мероприятий, соблюдения рекомендаций по здоровому образу жизни, в том числе рекомендаций в плане здорового питания), партисипативность (предоставление возможностей и средств, способствующих персонализированному информированию, просвещению и мотивированию человека к активному вовлечению в управление своим здоровьем).

Несмотря на большое число действующих медицинских информационных систем, развитию и масштабированию технологий 4П-медицины в России препятствует отсутствие в них инструментов, способных облегчить и автоматизировать на основе указанных принципов как работу медицинских специалистов с большим количеством граждан, так и самих граждан по управлению собственным здоровьем, чтобы своевременно заметить тревожные признаки и, при необходимости, обратиться к врачу. Как отмечается в [1], реализация перечисленных принципов предусматривает использование новых инструментов сбора информации, среди которых особое место должны занять пациентоцентрированные методы оценки (*англ.* patient-reported outcome measures).

Набор приложений в составе платформы Biogenom демонстрирует ориентацию на соблюдение указанных принципов. Помимо описываемого сервиса «Диагностика здоровья», в состав платформы входят такие сервисы: «Менеджер здоровья» – для реализации плана улучшения / поддержки здоровья (позволяет создавать цели по улучшению здоровья, использовать инструменты для достижения поставленных целей, анализировать статистику их достижения за любой период); «Дневник здоровья» – для автоматизации ведения журнала, где сохраняются различные показатели здоровья человека (температура, давление и др.), набор которых рекомендуется к отслеживанию на основании половозрастной группы пользователя и результатов анкетирования при использовании других сервисов платформы; «Расшифровка анализов» – для автоматизированного распознавания бланков с результатами лабораторных исследований в виде файлов изображений и PDF с интерпретацией полученных результатов и выдачей типовых рекомендаций о возможных причинах отклонений в показателях с указанием специальностей врачей, к которым следует обратиться; «Консультация специалиста» – чат для проведения онлайн-консультаций специалистов: нутрициологов, врачей-диетологов и др.; «Аватар здоровья» – для визуального отображения результатов анализа данных о здоровье конкретной персоны; информационный сервис, позволяющий оформить заявку / записаться на конкретный временной слот для получения услуг по здоровьесбережению, выбрав из предлагаемого списка подходящую пользователю медицинскую организацию.

Для демонстрации возможностей системы на рис. 1 представлены примеры некоторых экранов сервисов платформы Biogenom: основное меню, меню сервиса «Диагностика здоровья» («Оценка здоровья») и фрагменты экранов опросника сервиса «Диагностика здоровья», где пользователь указывает суточное потребление 2-х выбранных им продуктов (хлеб и морская рыба).




Рис. 1. Примеры интерфейса мобильного приложения

С технологической точки зрения для реализации перечисленных сервисов в соответствии с принципами 4П-медицины используется интеграция методов и средств онтологического инжиниринга, генеративного искусственного интеллекта и традиционных технологий баз данных. Мы сознательно ограничиваем роль сервисов генеративного ИИ и отводим ему только вспомогательные функции по визуализации финальных отчетов и рекомендаций в удобной для пользователя форме и генерации изображений (на рис. 1 сгенерированные изображения содержат подсказки по объему выбранных продуктов) ввиду широко обсуждаемых недостатков не только в связи с рисками нарушения конфиденциальности и безопасности данных, но и опасности так называемой предвзятости его алгоритмов. Если обучающие данные недостаточно разнообразны, рекомендации могут быть неточными для определенных групп людей, что нарушает принцип персонализации и может привести к неправильным советам и рекомендациям по питанию, ухудшив тем самым состояние здоровья конкретного человека. Еще одна проблема – недостаточный по сравнению с технологиями инженерии знаний (символический ИИ) уровень объяснительной компоненты и риск слишком сильно зависеть от технологий машинного обучения, тогда как в настоящее время опыт нутрициологов и врачей-диетологов широко представлен как в официальной медицинской литературе, так и в доступных базах данных и знаний.

В течение двух последних десятилетий во многих странах при финансовой поддержке правительств создавались и совершенствовались национальные базы знаний онтологического типа о нутриентном составе продуктов питания, которые до сих пор поддерживаются в актуальном состоянии. Некоторые из этих онтологий и баз данных открыты как для научных исследований, так и для использования в коммерческих целях, но требуют адаптации под национальные особенности продуктов питания и учета соответствующих нормативных документов.

Такая работа была выполнена с участием представителей экспертного сообщества Союза «Здоровье Здоровых». За основу взята онтология Федерального управления по безопасности пищевых продуктов и ветеринарии FSVO о составе пищевых продуктов, доступных в Швейцарии (<https://naehrwertdaten.ch/en/>). Текущая версия швейцарской базы данных о составе пищевых продуктов (версия 7.0) содержит информацию о более чем 1220 продуктах питания, их макроэлементах (жирах, насыщенных жирных кислотах, углеводах, сахаре, пищевых волокнах, белках), о содержании воды, алкоголя, энергии и питательных микроэлементах (витаминах, минералах).

Помимо адаптации данных к особенностям российских продуктов питания, была выполнена большая работа по семантической категоризации продуктов питания с учетом их нутриентного состава с тем, чтобы разработать краткий (30 вопросов) и развернутый (100 вопросов) опросник. В результате пользователь постепенно отвечает на вопросы, начиная с выбора категорий продуктов верхнего уровня (их всего 12) и имеет возможность пропустить те категории / подкатегории нижнего уровня, продукты которых не входят в его рацион питания. Интерфейс опросника является онтологически управляемым, поэтому для реализации развернутого опросника, расширения системы и пополнения выдаваемых рекомендаций не требуется вносить изменения в исходный код приложения: необходимо внести изменения только в базу знаний системы.

На рис. 2 представлены фрагменты экранов с результатами диагностики и рекомендациями сервиса «Диагностика здоровья» в части оценки содержания макро- и микронутриентов в составе продуктов питания конкретной персоны относительно официальных норм. После оценки текущего суточного потребления персоны (1-й экран) формируются рекомендации по питанию и другим товарам персонализированного набора (2-й экран), объясняется влияние недостатка нутриентов (на экране 3 представлена часть рекомендаций и объяснений при недостатке йода) и выводится часть индивидуального отчета с демонстрацией новых возможных результатов мониторинга в случае, если будут приняты текущие рекомендации системы с учетом персонализированного набора товаров (4-й экран).




Рис. 2. Экраны с результатами диагностики и рекомендациями

Заключение. Применяемый гибридный подход, сочетающий символический ИИ с другими методами, обеспечивает ряд преимуществ, среди которых модельно-управляемая адаптивность является ключевым отличием, так как вся логика работы приложений управляется онтологией. Это позволяет экспертам в явном виде обновлять, расширять и верифицировать базу знаний, что критически важно в медицинской сфере и соответствует тренду на создание доверительного ИИ. В ближайших планах – совершенствование микросервисной архитектуры платформы Biogenom, приложения которой доступны для скачивания по адресу <https://play.google.com/store/apps/details?id=ru.biogenom.mobile.android>

Библиографический список

1. Мартюшев-Поклад А. В., Савицкая Н. Г., Янкевич Д. С. Разработка опросника для комплексной оценки функциональных нарушений в модели 4П-медицины // Социальные аспекты здоровья населения. 2024. № 70 (6). Статья 10. DOI 10.21045/2071-5021 2024-70-6-10
2. Об утверждении Концепции предиктивной, превентивной и персонализированной медицины: приказ Минздрава от 24.04.2018 № 186. URL: <https://www.garant.ru/products/ipo/prime/doc/71847662/> (дата обращения: 22.09.2025).
3. Чудаков С. Ю., Кузнецов П. П., Хан Н. В., Симонова А. В. Стратегия развития персонализированной превентивной медицины в России в перспективе 2035 года // Менеджмент качества в медицине. 2019. № 1. С. 114–118.

BIOGENOM: AN INTELLIGENT ASSISTANT IN HEALTH FOOD MONITORING

Svetlana I. Chuprina

Perm State Humanitarian Pedagogical University
24, Sibirskaya Str., Perm, Russia, 614990
chuprinas@inbox.ru

Alexey N. Dubasov

BIOGENOM LLC
93, Nikolay Ostrovsky Str., Perm, Russia, 614990
dubasov@biogenom.ru

Igor S. Postanogov

Perm State University
15, Bukireva Str., Perm, Russia, 614068
postanogov@biogenom.ru

Kseniya V. Gimasheva

BIOGENOM LLC,
93, Nikolay Ostrovsky Str., Perm, Russia, 614990
gimashevaksusha1@gmail.com

The paper describes conceptual and technological aspects of the development of an intelligent assistant in health food monitoring. The service is a part of the digital platform of Biogenom and was developed as a mobile application that performs the role of an intelligent assistant in health food monitoring based on modern principles of 4P-medicine. The technological basis of the development is the integration of methods and tools of ontology engineering, generative artificial intelligence and traditional database technologies.

Keywords: 4P-medicine, healthy nutrition monitoring, intelligent assistant, ontology engineering, generative AI, health risk assessment

ПРИМЕНИМОСТЬ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ КЛАССИФИКАЦИИ ТИПОВ АБЗАЦЕВ С ЦЕЛЮ ИСПОЛЬЗОВАНИЯ В СИСТЕМЕ АВТОМАТИЧЕСКОГО ФОРМАТИРОВАНИЯ

Аккузина Виктория Михайловна

Национальный исследовательский университет
«Высшая школа экономики» (НИУ ВШЭ – Пермь)
614070, Россия, г. Пермь, ул. Студенческая, 38
vmakkuzina@edu.hse.ru

В статье представлено описание разработки нейросетевой системы для классификации типов абзацев в текстовых документах. Система позволяет с высокой точностью определять тип абзаца на основе форматных параметров, статистических характеристик текста и семантических индикаторов. Решение направлено на автоматизацию проверки и корректировки форматирования в учебных документах, что способствует снижению трудозатрат преподавателей и студентов. Проведен анализ признаков, значимости параметров и качества модели.

Ключевые слова: нейросетевые технологии, классификация абзацев текста, форматирование документов, текстовые документы

Введение. Соблюдение требований к форматированию текстовых документов является одной из актуальных задач современной образовательной сферы. Студенты и преподаватели вынуждены тратить значительное количество времени на изучение регламентов оформления, их ручное применение, последующую проверку и корректировку. При этом процесс зачастую носит итеративный характер: документы проходят несколько циклов правок, что увеличивает трудозатраты. Реализация автоматизированной системы, способной выполнять проверку и исправление форматирования, представляется логичным и обоснованным решением, но ее внедрение сопряжено с рядом существенных сложностей [1–2].

Во-первых, несмотря на существование государственных стандартов оформления текстовых документов (таких как ГОСТ 7.32-2017 «Отчет о научно-исследовательской работе. Структура и правила оформления» [3] и др.), зачастую используются локальные регламенты, которые уточняют, дополняют или противостоят стандарту, соответственно использование нескольких ГОСТов не обеспечит должной универсальности системы.

Во-вторых, форматирование может осуществляться несколькими способами: с использованием прямого и стилевого форматирования или их комбинации. Такое разнообразие создает неоднозначность при интерпретации: например, абзац,

относящийся к стилю «Обычный текст», может визуально соответствовать стилю заголовка за счет прямого форматирования. В таком случае требуется анализ контекста, поскольку абзац можно интерпретировать как заголовок, как обычный текст или, возможно, как элемент нумерованного списка.

В-третьих, авторы документов часто допускают ошибки по разным причинам, среди которых незнание требований, неумение использовать инструмент и невнимательность.

В таких условиях rule-based-системы теряют свою эффективность, в связи с чем в рамках данной работы ставится задача разработать и протестировать нейросетевую модель для классификации типов абзацев в текстовых документах в рамках предметной области программной инженерии и на основе стандарта форматирования образовательной программы «Разработка информационных систем для бизнеса».

Кроме того, необходимо исследовать потенциал модели к обобщению, т.е. понять, применима ли модель к документам других предметных областей и регламентов форматирования. Конечным результатом работы является нейросетевая система, способная классифицировать типы абзацев с высокой точностью в заданной предметной области.

Сбор данных происходит на базе лабораторных работ по программированию студентов первого курса образовательной программы НИУ ВШЭ – Пермь «Разработка информационных систем для бизнеса» за 2023–2024 учебный год.

Постановка задачи и формирование DataSet. Для создания нейросетевой системы были выбраны следующие параметры: к числовым признакам относятся X1 – «Размер шрифта», X3 – «Междустрочный интервал», X4 – «Длина абзаца (в знаках, с пробелами)», X5 – «Длина абзаца (в словах)», X6 – «Количество предложений», X7 – «Количество знаков препинания», X8 – «Количество цифр», X9 – «Количество латинских букв»; среди бинарных признаков X2 – «Наличие полужирного начертания», X10 – «Наличие ключевых слов, связанных с изображениями», X11 – «Наличие ключевых слов, связанных с таблицами». Выходной параметр D1 – тип конкретного абзаца, который принимает одно из пяти значений, соответствующих структурным элементам документов: 1 – «Заголовок», 2 – «Обычный текст», 3 – «Пункт списка», 4 – «Наименование таблицы», 5 – «Подпись к изображению».

Данные были вручную размечены, статистические характеристики текста извлечены с помощью Python-скриптов, после чего множество было очищено от выбросов с помощью программы «Нейросимулятор 4» [4–5].

Абзацы, являющиеся заголовками третьего, четвертого и следующих уровней, обладают признаками, схожими с признаками других типов абзацев, что затрудняет их однозначную классификацию. Такие данные были идентифицированы программой как аномалии, однако, учитывая их высокую частоту использования, было принято решение сохранить их в выборке.

Итоговый набор данных составил 489 объектов, из которых в случайном порядке были выделены обучающее, валидирующее и тестовое множества в соотношении 70% (342 примера), 20% (98 примеров) и 10% (49 примеров) соответственно.

Проектирование, обучение и тестирование нейросети. Для решения задачи была реализована нейросетевая модель на основе многослойного перцептрона (MLP) со следующей архитектурой: 9 входных нейронов, один выходной нейрон с линейной функцией активации и пять скрытых слоев с 16, 32, 16, 8 и 1 нейронами соответственно.

В рамках тестирования гипотезы задача классификации типов абзацев сведена к регрессии, выходное значение модели округляется до ближайшего целого числа, соответствующего коду целевого класса.

Следует отметить, что данный подход является упрощением постановки задачи и не обеспечивает корректной оценки вероятностей принадлежности к классам. В перспективе реального использования для повышения качества и надежности классификации планируется переход к стандартной архитектуре с выходным слоем softmax и числом нейронов, равным количеству классов.

Обучение модели проводилось в течение 500 эпох с использованием алгоритма обратного распространения ошибки и функции потерь MSE, что соответствует регрессионной постановке задачи.

Дополнительно был проведен анализ корреляции Спирмена между признаками (рис. 1). Как и ожидалось, выявлена высокая корреляция между статистическими признаками X4 – «Длина абзаца (в знаках, с пробелами)» и X5 – «Длина абзаца (в словах)». Неожиданно высокая корреляция была обнаружена между числовым признаком X3 – «Междустрочный интервал» и бинарным X2 – «Наличие полужирного начертания». Было принято решение исключить признак X4 из дальнейшего анализа и параметров модели.




Рис. 1. Мультиколлинеарность признаков

Была оценена значимость параметров нейросетевой системы: наибольшее влияние на результат классификации абзацев оказывают признаки X5 – «Длина абзаца (в словах)», X3 – «Междустрочный интервал» и X2 – «Наличие полужирного начертания» (рис. 2).




Рис. 2. Значимость входных параметров нейросетевой модели

На тестовом множестве (49 примеров) модель показала следующие результаты: средняя абсолютная ошибка (MAE) составила 7%, точность модели – 87%. Графическое сравнение реальных и предсказанных значений представлено гистограммой на примере 30 случайных примеров (рис. 3).




Рис. 3. Результат тестирования нейронной сети

Анализ ошибок показал, что модель испытывает трудности при различении обычного текста и пунктов списка, что связано с их визуальной и структурной схожестью. Также отмечено, что заголовки третьего уровня практически всегда классифицируются как обычный текст, что является признаком недостатка результирующих классов.

Заключение. Проведенное исследование подтверждает выдвинутую ранее гипотезу о применимости использования нейросетевых систем для классификации типов абзацев в текстовых документах. Несмотря на упрощенную постановку задачи, модель продемонстрировала высокую точность, что свидетельствует о перспективности подхода.

Для дальнейшего улучшения качества классификации следует рассмотреть добавление признаков, связанных с наличием маркера списка у абзацев, ввод иерархии заголовков, а также увеличить объем данных за счет документов из других предметных областей и регламентов форматирования.

Высокая точность предсказания типов абзацев была достигнута с помощью разработанной нейросетевой системы, обученной на 9 входных параметрах, среди которых важнейшими оказались длина абзаца, наличие полужирного начертания и междустрочный интервал абзаца.

Библиографический список

1. Стариченко Б. Е., Устинов М. А. Программа автоматизации контроля оформления текстовых документов // Педагогическое образование в России. 2018. № 8. С. 163–168.
2. Самойлова И. А. Сложность реализации автоматизированной проверки дипломных работ на соответствие техническим нормам // Молодой ученый. 2016. № 15. С. 149–152.
3. ГОСТ 7.32–2017. Отчет о научно-исследовательской работе. Структура и правила оформления.
4. Черепанов Ф. М., Ясницкий Л. Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
5. Черепанов Ф. М., Ясницкий Л. Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2008. № 4. С. 151–155.

APPLICABILITY OF NEURAL NETWORK MODELS FOR CLASSIFYING PARAGRAPH TYPES FOR USE IN AN AUTOMATIC FORMATTING SYSTEM

Viktoria M. Akkuzina

HSE University

38, Studencheskaya Str., Perm, Russia, 614070

vmakkuzina@edu.hse.ru

The article describes the development of a neural network system for classifying paragraph types in text documents. The system allows for high-precision determination of paragraph type based on formatting parameters, statistical characteristics of the text, and semantic indicators. The solution is aimed at automating the verification and correction of formatting in educational documents, which helps to reduce the workload of teachers and students. An analysis of the features, significance of parameters, and quality of the model was conducted.

Keywords: artificial intelligence, neural network technologies, text paragraph classification, document formatting, text documents

ПРОГРАММНОЕ МОДЕЛИРОВАНИЕ И ВИЗУАЛИЗАЦИЯ ЛЕКСИКО-СЕМАНТИЧЕСКИХ СВЯЗЕЙ В МУЛЬТИЯЗЫЧНОМ СЛОВАРЕ БАС НА ОСНОВЕ FRAMENET И WORDNET

Фадеева Александра Дмитриевна

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
gerasimova070702@gmail.com

Исаева Екатерина Владимировна

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
ekaterinaisae@gmail.com

Ракина Мария Сергеевна

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

В статье описан метод автоматического анализа и наглядного представления терминологии, связанной с беспилотными авиационными системами (БАС). Данный подход основан на применении лингвистических ресурсов FrameNet и WordNet и реализован с помощью языка программирования Python и библиотек NLTK и pyvis. Программный модуль состоит из двух элементов: первый направлен на извлечение и предобработку данных и анализ лексико-семантических связей; второй – на создание интерактивных визуализаций сложных смысловых отношений. Разработанный программный модуль позволяет формировать многоязычные словари с визуализацией лексико-семантических связей, что важно для точного понимания и перевода технической лексики. Полученные результаты могут быть использованы для анализа технической документации по БАС, в переводческих сервисах и прикладных лингвистических исследованиях.

Ключевые слова: фреймовая лингвистика, FrameNet, WordNet, лексико-семантический анализ, мультязычный словарь, беспилотные авиационные системы, Python, интерактивная визуализация, pyvis, NLTK

Введение. Актуальные задачи автоматизированного анализа и репрезентации узкоспециализированной лексики, в частности при разработке многоязычных лексиконов для терминологии беспилотных авиационных систем (БАС), обуславливают необходимость интеграции лингвистических моделей и программных средств для расширения лексикона. Комбинированное использование фреймовой лингвистики (FrameNet) и онтологических ресурсов (WordNet) обеспечивает надежную основу для семантической интерпретации терминологии [1, 2].

Представленное в данной работе исследование направлено на изучение лексики, потенциально участвующей в реализации типичных сценариев номинативных терминов БАС, представляющих беспилотные летательные аппараты (БПЛА, беспилотники, дроны, квадрокоптеры и др.). В задачи исследования входит разработка способа автоматической компиляции и семантического обогащения списка глаголов, отражающих движение.

Методы. В работе исследуется потенциал программно-ориентированного подхода к изучению лексики, базирующегося на двух ключевых компонентах: автоматизированном извлечении и структурировании лингвистических данных на языке Python с задействованием библиотек Pandas, NLTK, FrameNet и WordNet, а также интерактивной визуализации семантических корреляций посредством инструмента ruvis. Эти методы позволяют работать с табличными данными, автоматически извлекать данные из лингвистических корпусов, формировать мультязычные словари, обогащенные лексико-семантической разметкой, что особенно ценно для устранения неоднозначностей в текстах узкоспециализированных или наукоемких предметных областей, таких как БАС.

Выбор фреймовой лингвистики, основанной на работах Ч. Филлмора, для разработки мультязычных специализированных словарей, в частности для терминологии БАС, обусловлен ее преимуществами в семантическом анализе [3]. Ключевым элементом является семантический фрейм – структурированное представление ситуации, включающее указание на ее участников, их ролей и особенностей их реализации в контексте. Данный подход, ориентированный на взаимосвязи и контекстуальное значение, обеспечивает когнитивно обоснованное описание и систематизацию специализированной лексики.

Фрейм представляет собой организованную структуру знаний, предназначенную для моделирования типичных ситуаций. Эта структура включает в себя множество взаимосвязанных компонентов – фреймовых элементов (Frame Elements), каждый из которых выполняет определенную функциональную роль [14]. В качестве иллюстрации представим фрейм «Motion» (движение), который описывает процесс перемещения и включает такие роли, как агент, средство, путь и цель. В силу данной характеристики он представляет значительный интерес для анализа лексики, связанной с управлением и особенностями эксплуатации БАС.

Кроме того, использование фреймовой лингвистики оправдано ее способностью моделировать лексическое значение в контексте, что позволяет осуществлять более глубокий и осмысленный анализ технической лексики и терминологии, а также их мультязычных эквивалентов. Данный подход особенно ценен при формировании и структурировании лексикографических ресурсов, где точность и контекстуальное понимание приобретают первостепенное значение.

Важную роль в нашем подходе играет применение онтологических баз данных, таких как WordNet [2]. Они обогащают фреймовый анализ, предоставляя подробные сведения о лексических связях (синонимия, гиперонимия, гипонимия и т.д.). Это позволяет глубже понять значения терминов, выстроить их в сложную сеть взаимосвязей и повысить качество многоязычных словарей [4].

Для эффективного анализа и представления результатов исследования используются современные методы визуализации. Интерактивные инструменты на основе библиотеки ruvis [5, 13] наглядно демонстрируют сложные семантические отношения между фреймами, ролями и словами. Это упрощает понимание данных, способствует более глубокому анализу и выявлению новых закономерностей, что особенно ценно для узкоспециализированных областей, например для лексики, связанной с БАС [6].

Актуальность исследования обуславливает необходимость применения автоматизированных подходов к сбору и анализу лингвистических данных в предметно-ориентированных областях, в частности в сфере лексики БАС. В рамках настоящего исследования были разработаны два программных модуля, предназначенные для осуществления углубленного лексико-семантического анализа и обеспечения наглядной репрезентации его результатов.

Результаты. Первый элемент модуля разработан на языке программирования Python с применением библиотеки NLTK, а именно модуля `framenet` версии `framenet_v17`, импортированного из `nltk.corpus`. В начале работы загружается семантический фрейм «Motion» из базы данных FrameNet: `frame = fn.frame('Motion')`. Это позволяет выделить глаголы, описывающие движение: `verbs = [lu for lu in frame.lexUnit.values() if lu['POS'].lower() == 'v']`. Было извлечено 23 глагола на английском языке: *move, go, drift, glide, blow, float, coast, roll, soar, fly, slide, swerve, snake, meander, undulate, weave, wind, zigzag, circle, spiral, swing, travel, come*. Данная выборка необходима для понимания лексики, описывающей движение, что входит в лексико-семантическое ядро понятия БАС. Использование FrameNet позволяет получить структурированное представление знаний типичных сценариев реализации термина.

Для более глубокого изучения лексикона, потенциально репрезентирующего сценарии реализации термина БАС в профессиональной коммуникации, перечень глаголов фрейма «Motion» был обогащен синонимическими, гиперонимическими и гипонимическими связями. Так, для каждого глагола фрейма «Motion» выполняется поиск синонимов (`syn.lemmas`), гиперонимов (`syn.hypernyms`) и гипонимов (`syn.hyponyms`), а также извлекаются определения (`wn_info["definition"]`) и примеры использования (`wn_info["examples"]`) из WordNet (рис. 1). Интеграция с WordNet позволяет обогатить результат, полученный на этапе работы с Frame Net, семантически близкими терминами. Такой комплексный подход к извлечению информации из открытых лингвистических корпусов позволяет создавать подробные лексико-семантические профили терминов, что важно для разработки точных мультязычных словарей, учитывающих специфику и многозначность технической лексики, используемой в области БАС.

	Verb	Definition	Synonyms	Hypernyms	Hyponyms	Example	Frame Elements
0	move	change location; move, travel, or proceed, also metaphorically	travel, locomote, go, move		travel, whisk, range	How fast does your new car go?	Theme, Source, Path, Goal, Area, Distance, Speed, Carrier, Duration, Time, Manner, Result, Depictive, Place, Degree, Direction, Purpose, Path_shape, Containing_event, Frequency, Iterations
1	go	change location; move, travel, or proceed, also metaphorically	travel, locomote, go, move		travel, whisk, range	How fast does your new car go?	Theme, Source, Path, Goal, Area, Distance, Speed, Carrier, Duration, Time, Manner, Result, Depictive, Place, Degree, Direction, Purpose, Path_shape, Containing_event, Frequency, Iterations
2	drift	be in motion due to some air or water current	blow, drift, be_adrift, float	travel, locomote, go	tide, waft, stream	The leaves were blowing in the wind	Theme, Source, Path, Goal, Area, Distance, Speed, Carrier, Duration, Time, Manner, Result, Depictive, Place, Degree, Direction, Purpose, Path_shape, Containing_event, Frequency, Iterations
3	glide	move smoothly and effortlessly	glide	travel, locomote, go	plane, surfboard, slip		Theme, Source, Path, Goal, Area, Distance, Speed, Carrier, Duration, Time, Manner, Result, Depictive, Place, Degree, Direction, Purpose, Path_shape, Containing_event, Frequency, Iterations
4	blow	exhale hard	blow	breathe_out, exhale, expire	heave, puff, gasp	blow on the soup to cool it down	Theme, Source, Path, Goal, Area, Distance, Speed, Carrier, Duration, Time, Manner, Result, Depictive, Place, Degree, Direction, Purpose, Path_shape, Containing_event, Frequency, Iterations
5	float	be in motion due to some air or water current	blow, drift, be_adrift, float	travel, locomote, go	tide, waft, stream	The leaves were blowing in the wind	Theme, Source, Path, Goal, Area, Distance, Speed, Carrier, Duration, Time, Manner, Result, Depictive, Place, Degree, Direction, Purpose, Path_shape, Containing_event, Frequency, Iterations

Рис. 1

Использование автоматического фреймового отбора лексики, связанной с движением БАС, и семантического обогащения через WordNet позволяет учитывать вариативность языковых средств при описании типичных ситуаций, обеспечивает иерархическую организацию понятий, облегчает межъязыковое сопоставление и отражает когнитивную структуру ментального лексикона. Данная методика обеспечивает контекстуализацию и семантическую насыщенность лексикона, формируя тем самым предпосылки для упрощения процесса технического перевода и корректного употребления терминологии в многоязычных средах.




Рис. 2

Визуализация дополнена всплывающими подсказками, которые предоставляют дополнительный контекст, например синонимы и примеры из WordNet. Это делает визуализацию не только наглядной, но и информативной, что полностью соответствует современным тенденциям в семантическом анализе и разметке, используемым в лингвистике [7, 13]. Совместное использование с библиотекой NetworkX позволяет глубже изучать граф, анализируя его сетевые свойства: важность узлов, их объединения и связи. Это делает решение более ценным как для научных лингвистических изысканий, так и для практического создания многоязычных специализированных словарей.

Обсуждение. Представленная интерактивная визуализация лексико-семантических связей является интуитивно понятным инструментом, облегчающим анализ и изучение сложных лингвистических структур. Благодаря применению цветового кодирования, всплывающих подсказок и функционала масштабирования пользователи получают возможность оперативно идентифицировать ключевые элементы и их взаимоотношения в сетевых представлениях. Это способствует более глубокому и комплексному когнитивному моделированию предметных областей.

Несмотря на преимущества автоматизации лингвистических исследований, такой подход не лишен недостатков. В частности, следует отметить, что формирование обогащенного списка глаголов движения выполнялось без привязки к контексту, т.е. оценка вероятности встречаемости коллокаций номинативных терминов предметной области БАС с глаголами-кандидатами не была реализована, что является перспективой для последующих изысканий в данной области.

Заключение. В работе представлен программный подход к автоматизированному извлечению и визуализации лексико-семантических связей для обогащения многоязычного словаря терминов БАС. Использование лингвистических ресурсов FrameNet и WordNet в сочетании с библиотеками Pandas, NLTK и pyvis позволило создать инструмент для быстрой компиляции лексиконов. Разработанный метод может быть масштабирован на другие предметные области при условии предварительного фреймового моделирования и выявления фреймов-кандидатов для исследуемых терминов.

Библиографический список

1. Baker C. F., Fillmore C. J., Lowe J. B. The Berkeley FrameNet Project // Proceedings of the 36th Annual Meeting of the Association for Computational Linguistics and 17th International Conference on Computational Linguistics. Montreal: Association for Computational Linguistics, 1998. P. 86–90. URL: <https://aclanthology.org/P98-1013/> (дата обращения: 22.09.2025).
2. WordNet: An Electronic Lexical Database / ed. by C. Fellbaum. Cambridge: MIT Press, 1998.
3. Fillmore C. J. Frame Semantics // Linguistics in the Morning Calm. Seoul: Hanshin Publishing Co., 1982. P. 111–137.
4. Bond F., Paik K. Overview of the Open Multilingual WordNet // Proceedings of LREC. Istanbul, 2012.
5. Hassell J., Aleman-Meza B., Arpinar I. B. Ontology-Driven Automatic Entity Disambiguation in Unstructured Text // Cruz I. et al. The Semantic Web – ISWC 2006. ISWC 2006. Lecture Notes in Computer Science, vol 4273. Springer, Berlin, Heidelberg, 2006. DOI [10.1007/11926078_4](https://doi.org/10.1007/11926078_4)
6. Sarnat A., Joshi V., Petrescu-Prahova C. et al. Interactive Visualization for Linguistic Structure // Proceedings of the Conference on Empirical Methods in Natural Language Processing. 2017.
7. Jakubowski P. Extending FrameNet to Machine Learning Domain. 2022. 12 p.
8. Marzinotto G. FrameNet Annotations Alignment using Attention-based Machine Translation // Proceedings of the International FrameNet Workshop 2020: Towards a Global, Multilingual FrameNet. Marseille: European Language Resources Association, 2020. P. 41–47. URL: <https://aclanthology.org/2020.frame-net-1.6/> (дата обращения: 22.09.2025).
9. Hagberg A., Schult D., Swart P. Exploring Network Structure, Dynamics, and Function using NetworkX // Proceedings of the 7th Python in Science Conference. Pasadena, 2008.
10. Borgatti S. P., Halgin D. S. On Network Theory // Organization Science. 2011.
11. Jones A., Caswell I., Saxena I., Firat O. Bilex Rx: Lexical Data Augmentation for Massively Multilingual Machine Translation. 2023.
12. Lönneker-Rodman B. The FrameNet model and its applications // Natural Language Engineering. 2009.

13. Interactive network visualizations: Pyvis documentation. 2023. URL: <https://pyvis.readthedocs.io/> (дата обращения: 22.09.2025).

14. Вековищева С. Н. Фреймовое моделирование лексической семантики // Вестник филологического факультета. 2017.

PROGRAMMATIC MODELING AND VISUALIZATION OF LEXICO-SEMANTIC RELATIONS IN A MULTILINGUAL UAV DICTIONARY BASED ON FRAMENET AND WORDNET

Fadeeva Alexandra Dmitrievna

Perm State University
15, Bukireva Str., Perm, Russia, 614990
gerasimova070702@gmail.com

Isaeva Ekaterina Vladimirovna

Perm State University
15, Bukireva Str., Perm, Russia, 614990
ekaterinaisae@gmail.com

Rakina Maria Sergeevna

Perm State University
15, Bukireva Str., Perm, Russia, 614990
mmartess@yandex.ru

This paper describes a method for automatic analysis and visual representation of terminology related to unmanned aerial vehicles (UAVs). The approach integrates the linguistic resources FrameNet and WordNet, implemented using Python and the NLTK and pyvis libraries. The first part of the code extracts and organizes lexico-semantic data, while the second creates interactive visualizations of complex semantic relations. The developed tools enable the creation of multilingual dictionaries with rich semantic content, which is critical for accurate understanding and translation of technical vocabulary. The obtained results can be applied in UAV control systems, translation services, and applied linguistic research.

Keywords: frame semantics, FrameNet, WordNet, lexico-semantic analysis, multilingual dictionary, unmanned aerial vehicles, Python, interactive visualization, pyvis, NLTK

НЕЙРОСЕТЕВОЕ ИССЛЕДОВАНИЕ ЗАВИСИМОСТИ ПОПУЛЯРНОСТИ КОНТЕНТА ОТ ЕГО СОДЕРЖАНИЯ

Рабчевский Андрей Николаевич

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

Жданова Светлана Юрьевна

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
svetlanaur@gmail.com

В статье представлены результаты нейросетевого исследования зависимости потенциала распространения текстов в социальных сетях в зависимости от использованных в них психологических приемов. Созданный для этих целей датасет и обученная нейросеть позволили выявить весовые коэффициенты каждого из приемов, что дало возможность повысить уровень точности прогнозирования популярности контента в сети.

Ключевые слова: нейросетевые технологии, психологические приемы, весовые коэффициенты, прогнозирование популярности контента

Введение. Развитие информационных технологий и цифровизация общества привели к тому, что различные социальные сети и мессенджеры стали играть существенную роль в управлении и манипулировании общественным сознанием, что регулярно используется нашими геостратегическими противниками. Очевидно, что в рамках текущей информационной войны противодействие такому манипулированию приобретает наиважнейшее значение. Для того чтобы противостоять информационным атакам противника и предсказывать масштабы атак и возможный уровень охвата аудитории, необходимо уметь прогнозировать параметры распространения деструктивной информации в сети. Такое прогнозирование должно основываться на корректном моделировании сетевых процессов. Одним из параметров, который необходимо учитывать при моделировании, является популярность распространяемого контента.

Проблема предсказания популярности текста давно волнует исследователей, многие из которых предлагают разнообразные подходы. Исследуя вопрос популярности контента в работе Zhu и др. [1], авторы утверждают, что популярность зависит от уровня влияния пользователя, а он в свою очередь зависит как от структурных свойств социальной сети, так и от содержания контента, который публикуют пользователи. Это подтверждается исследованиями, описанными в работе [2], где под потенциалом влияния понимается сочетание как структурных свойств сети, так и публикационной активности автора. Однако влияние в социальных сетях, как правило, рассматривается исследователями в контексте максимально возможного влияния, или потенциала влияния пользователя. При этом одинаковые параметры потенциала влияния различных пользователей не означают, что они одинаково реализуют свой потенциал. Это подтверждается исследованиями,

описанными в работе [3], где показано, что не существует прямой корреляции между потенциалом влияния наиболее влиятельных пользователей и реакцией других пользователей сети на их публикации. Таким образом, популярность, скорее, зависит от содержания текста, чем от структурных свойств сети.

Для предсказания популярности контента различные авторы применяют различные методы. Так, Gabor Szabo и др. [4] используют динамику начальной реакции на контент и не учитывают при этом ни структуру сети, ни содержание контента. Wojciech Stokowiec и др. для предсказания популярности контента использовали метод на основе анализа заголовков [5]. В основе их метода лежит бинарная классификация, когда контент считается популярным, если его метрика (например, количество просмотров или комментариев) превышает медианное значение для датасета. На самом деле нейросеть не анализировала содержание заголовков, она обучалась предсказывать популярность текстов и видео по метрикам реакции и после этого сопоставляла вектор заголовка с показателями популярности. В работе [6] авторы прогнозировали популярность петиций, которая обычно измеряется количеством подписей. Прогноз выполнялся на основе анализа текстового содержания петиций. Все текстовые поля петиции объединялись в один текст, токенизировались с помощью предобученных GloVe эмбедингов и далее обрабатывались глубокой сверточной сетью. В данном случае мы уже видим анализ контента, но данный метод использует статистическую информацию, обучаясь на ненулевых элементах матрицы совпадений слов, не анализируя при этом само содержание текстов. Есть и другие подходы к предсказанию популярности текстов, представленные в работах [7–17].

В целом можно сказать, что для предсказания популярности контента предложенные ранее методы компенсируют слабость глубокого анализа контента различными дополнительными признаками или совершенно оригинальными подходами, вообще не предполагающими анализ контента.

В то же время интересно исследовать, как на уровень реализации потенциала влияния влияет именно само содержание контента. Особенно интересен психологический аспект, который имеет важное значение для управления сознанием или подсознанием тех пользователей, на которых оно направлено посредством распространяемых текстов. Очевидно, что с точки зрения психологии важно то, какие психологические приемы использованы в текстах и как они влияют на уровень популярности каждого текста, выраженный в количестве просмотров, репостов, комментариев и лайков. Однако такой подход практически не используется исследователями.

В общем случае термин «популярность контента» не совсем точно отражает искомую величину. С точки зрения распространения информации важна не сама популярность, а потенциал распространения информации (ПРИ) по сети.

Для исследования зависимости ПРИ от содержания текста мы выбрали семь наиболее часто встречающихся текстов из коллекции документов по одному популярному инфоповоду. Данные были получены с помощью поисковой системы SEUS¹. Для каждого текста была собрана информация о реакции на эти тексты

¹ Программный комплекс для поиска, мониторинга и анализа информации в открытом пространстве социальных сетей и мессенджеров // SEUSЛАБ = SEUS: Официальный сайт разработчика. URL: <https://www.seuslab.ru/seus> (дата обращения: 22.08.2025).

пользователей сети, включая просмотры, репосты, комментарии и лайки. В результате текст № 4 получил наибольшее количество реакций на один дубликат, что соответствует уровню ПРИ. Интересно, что реакции на разные тексты существенно отличаются друг от друга, из чего следует вывод, что содержание текстов имеет значение для величины ПРИ.

Экспертами-психологами был составлен перечень, состоящий из 28 психологических приемов (критериев), которые содержатся в предложенных текстах и могут существенно влиять на восприятие текста и желание пользователей его поддержать, одобрить, переслать или прокомментировать. Все эти реакции приводят к дальнейшему распространению информации по сети, поэтому их наличие в текстах может показать нам потенциал распространения текста по сети.

В сравнении с реальными данными реакций пользователей экспертные оценки совпали в оценке самого популярного текста № 4, а в оценке остальных текстов сильно различаются. Кроме того, была разработана программа оптимизации, которая вычислила веса каждого критерия с тем, чтобы результаты совпадали с реальными реакциями пользователей. Однако по данным программы для различных текстов одни и те же критерии имеют различные веса, поэтому были использованы усредненные показатели. В результате сравнения экспертные оценки очень слабо коррелируют с реальными данными, коэффициент корреляции Пирсона составляет 0,52. В то же время между усредненными расчетными весами критериев и реальными данными коэффициент корреляции Пирсона равен 0,89. Из этого следует, что гипотеза о том, что различные критерии имеют различные веса, математически подтверждается. Таким образом, основываясь на реальных данных, необходимо вычислить, какой вес имеет каждый из представленных критериев. Следует отметить, что для более точного учета влияния различных критериев был использован частотный анализ, предполагающий подсчет количества использованных критериев в каждом тексте, т.е. не просто использован прием в данном тексте или нет, но и то, сколько раз он использован.

Проектирование, обучение и тестирование нейросети. Исследование зависимости потенциала распространения информации от различных психологических приемов (критериев) выполнено с помощью нейросети. В качестве входных параметров нейросети были критерии и их количество, а выходного – потенциал распространения информации (суммарная реакция пользователей сети).

Для обучения нейросети создан датасет, содержащий реакцию пользователей на каждый текст и количество каждого использованного психологического приема. В результате получилось 28 входных параметров и одна выходная функция. Нейросеть состояла из 28 входных нейронов, одного скрытого слоя из 14 нейронов, одного выходного нейрона и активационной функции ReLu.

Для автоматической обработки текстов разработано две программы, одна из которых через VK API собирала реакцию на каждый пост в коллекции, а другая с помощью большой языковой модели выявляла и подсчитывала использованные психологические приемы. Всего было исследовано 4530 постов, на основании чего был создан датасет для обучения нейросети.

Исследование предметной области. В результате обучения нейросети и исследования зависимости выходной функции от входных параметров были получены ранги каждого психологического приема, представленные на рис. 1.



Рис. 1. Рейтинг психологических приемов, полученный в результате нейросетевого исследования

Использование весов психологических приемов, полученных с помощью нейросетевого исследования, в сочетании с частотным анализом на 7 тестовых текстах повысило коэффициент корреляции Пирсона относительно реальных данных до 0,88.

Заключение. Полученные данные свидетельствуют о том, что использование психологических приемов в текстах действительно может влиять на потенциал распространения текста в сети и при этом каждый психологический прием имеет различное влияние на потенциал распространения. Зная, сколько и каких психологических приемов было использовано в том или ином тексте и учитывая весовые коэффициенты каждого приема, можно предсказать, насколько эффективно тот или иной текст будет распространяться по сети. Использование этих параметров при моделировании параметров распространения информации в сети поможет построить более адекватную модель распространения и более точно предсказывать параметры информационных атак, их масштабы и уровень ущерба от них, а также поможет при моделировании методов противодействия информационным атакам, что позволит повысить информационную и психологическую безопасность пользователей социальных сетей.

Библиографический список

1. Zhu Z., Su J., Kong L. Measuring influence in online social network based on the user-content bipartite graph // Comput Human Behav. 2015. Vol. 52. DOI [10.1016/j.chb.2015.04.072](https://doi.org/10.1016/j.chb.2015.04.072)
2. Рабчевский А. Н., Рабчевский Е. А. Оценка потенциального уровня информационного влияния пользователей в социальных сетях // Информационные системы и технологии. 2022. № 1 (129). С. 114–122.
3. Жданов П. В., Мустакимова Я. Р., Рабчевский А. Н. Исследование реализации потенциала наиболее влиятельных пользователей // Актуальные проблемы информационной безопасности: сб. ст. Пермь: ПГНИУ, 2024. С. 10–18.
4. Szabo G., Huberman B. Predicting the popularity of online content. 2008. URL: <https://arxiv.org/abs/0811.0405>

5. Stokowiec W., Trzciński T., Wołk K. et al. Shallow Reading with Deep Learning: Predicting Popularity of Online Content Using only Its Title // *Foundations of Intelligent Systems*. P. 136–145. Springer International Publishing, 2017. DOI [10.1007/978-3-319-60438-1_14](https://doi.org/10.1007/978-3-319-60438-1_14)
6. Subramanian S., Baldwin T., Cohn T. Content-based Popularity Prediction of Online Petitions Using a Deep Regression Model. 2018. URL: <https://arxiv.org/abs/1805.06566>
7. Abbar S., Castillo C., Sanfilippo A. To Post or Not to Post: Using Online Trends to Predict Popularity of Offline Content // *Proceedings of the 29th on Hypertext and Social Media*. P. 215–219. ACM (2018). DOI [10.1145/3209542.3209575](https://doi.org/10.1145/3209542.3209575)
8. Garg N., Bhatia V., Bharath B. N. et al. Online Learning Models for Content Popularity Prediction in Wireless Edge Caching. 2019. URL: <https://arxiv.org/abs/1901.06476>
9. Jeon H., Seo W., Park E. L., Choi S. Hybrid Machine Learning Approach to Popularity Prediction of Newly Released Contents for Online Video Streaming Service. 2019. URL: <https://arxiv.org/abs/1901.09613>
10. Ding K., Wang R., Wang S. Social Media Popularity Prediction: A Multiple Feature Fusion Approach with Deep Neural Networks. 2019. DOI [10.1145/3343031.3356062](https://doi.org/10.1145/3343031.3356062)
11. Xu K., Lin Z., Zhao J. et al. Multimodal Deep Learning for Social Media Popularity Prediction with Attention Mechanism. 2020. DOI [10.1145/3394171.3416274](https://doi.org/10.1145/3394171.3416274)
12. Lin H.-H., Lin J.-D., Ople J. J. M. et al. Social Media Popularity Prediction Based on Multi-Modal Self-Attention Mechanisms // *IEEE Access*. 2022. Vol. 10. P. 4448–4455. DOI [10.1109/ACCESS.2021.3136552](https://doi.org/10.1109/ACCESS.2021.3136552)
13. Chen J., Liang D., Zhu Z. et al. Social Media Popularity Prediction Based on Visual-Textual Features with XGBoost // *Proceedings of the 27th ACM International Conference on Multimedia*. New York: Association for Computing Machinery, 2019. P. 2692–2696. DOI [10.1145/3343031.3356072](https://doi.org/10.1145/3343031.3356072)
14. Hsu C.-C., Lee C.-M., Hou X.-Y., Tsai C.-H. Gradient Boost Tree Network based on Extensive Feature Analysis for Popularity Prediction of Social Posts // *Proceedings of the 31st ACM International Conference on Multimedia*. New York: Association for Computing Machinery, 2023. P. 9451–9455. DOI [10.1145/3581783.3612843](https://doi.org/10.1145/3581783.3612843)
15. Lai X., Zhang Y., Zhang W. HyFea: Winning Solution to Social Media Popularity Prediction for Multimedia Grand Challenge 2020 // *Proceedings of the 28th ACM International Conference on Multimedia*. New York: Association for Computing Machinery, 2020. P. 4565–4569. DOI [10.1145/3394171.3416273](https://doi.org/10.1145/3394171.3416273)
16. Mao S., Xi W., Yu L. et al. Enhanced CatBoost with Stacking Features for Social Media Prediction // *Proceedings of the 31st ACM International Conference on Multimedia*. New York: Association for Computing Machinery, 2023. P. 9430–9435. DOI [10.1145/3581783.3612839](https://doi.org/10.1145/3581783.3612839)
17. Tan Y., Liu F., Li B. et al. An Efficient Multi-View Multimodal Data Processing Framework for Social Media Popularity Prediction // *Proceedings of the 30th ACM International Conference on Multimedia*. New York: Association for Computing Machinery, 2022. P. 7200–7204. DOI [10.1145/3503161.3551607](https://doi.org/10.1145/3503161.3551607)

NEURAL NETWORK STUDY OF THE DEPENDENCE OF THE POPULARITY OF CONTENT ON ITS CONTENT

Andrey N. Rabchevsky

Perm State University
15, Bukireva Str., Perm, Russia, 614990
ran@psu.ru

Svetlana U. Zhdanova

Perm State University
15, Bukireva Str., Perm, Russia, 614990
svetlanaur@gmail.com

The article presents the results of a neural network study of the dependence on the potential of text distribution in social networks, depending on the psychological techniques used in them. The dataset created for these purposes and the trained neural network made it possible to identify the weights of each of the algorithms, which made it possible to increase the level of accuracy of predicting the popularity of content on the network.

Keywords: neural network technologies, psychological techniques, weights, predicting the popularity of content

Искусственный интеллект и педагогика

УДК 37.016.7:811.111

СОВРЕМЕННОЕ ПРЕПОДАВАНИЕ АНГЛИЙСКОГО ЯЗЫКА: РЕВОЛЮЦИЯ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Антонова Надежда Александровна

Чувашский государственный университет имени И. Н. Ульянова
428000, Россия, г. Чебоксары, Московский пр., 15
nejda@rambler.ru

В статье рассматривается роль и значение технологий искусственного интеллекта (ИИ) в преподавании английского языка. На примере различных определений делается вывод о том, что современные технологии способны существенно трансформировать процесс обучения иностранным языкам, делая его более доступным, интересным и эффективным. Автор приводит примеры популярных сервисов и приложений, которые демонстрируют широкие возможности для развития навыков английского языка. Сделан вывод о том, что современные технологии ИИ ускоряют процесс обучения английскому языку, повышают мотивацию и укрепляют уверенность обучающихся.

Ключевые слова: искусственный интеллект, технологии, английский язык, обучение, студенты, эффективность

Введение. Бурное развитие технологий в нашу эпоху изменило многие аспекты жизни. Значительное влияние это развитие оказало и на процесс изучения английского языка [1, с. 8]. Стремительные трансформации требуют от каждого быстрой адаптации к этим изменениям. Глобализация и переход к технологиям порождают новые вызовы и возможности. Они играют решающую роль в предоставлении информации в самых разнообразных форматах – от аудио и текста до видео, упрощая для человека выполнение различных задач.

Одной из интенсивно развивающихся технологий является искусственный интеллект (ИИ). Джон Маккарти сыграл ключевую роль в становлении ИИ. Искусственный интеллект, по определению Джона Маккарти, это «свойство интеллектуальных систем выполнять творческие функции, которые традиционно считаются прерогативой человека» [2, с. 186]. Автор в своем определении подчеркивает свободу действий ИИ, выходящую за пределы программирования и инструкций. Иначе говоря, он говорит о системе, способной думать, рассуждать и совершать поступки, подобно человеческой. Он ассоциирует ИИ с «интеллектуальностью» и связывает машину с творчеством, свободой выбора и решением нестандартных задач.

По мнению И. Р. Бегишева и З. И. Хисамова, «искусственный интеллект – это когнитивно-интеллектуальная и адаптивно-автономная система, которая способна к осознанно-волевому поведению и имитирует деятельность нейронов

и нейронных сетей человеческого мозга» [3]. Ключевым моментом в определении авторов является «способность подражать», «демонстрировать осознанное поведение», «воспроизводить интеллектуальные процессы». Однако авторы подчеркивают, что реальный ИИ пока не достигает полноценного аналога человеческого сознания.

Л. С. Болотова определяет искусственный интеллект как «искусственную систему, способную имитировать интеллект человека, то есть способность получать, обрабатывать, хранить информацию и знания и выполнять над таковыми разные действия, совокупно называемые мышлением» [4]. Автор подчеркивает, что ИИ предназначен для того, чтобы повторять, воспроизводить и имитировать высшие когнитивные функции человека. Хотя описание выглядит реалистично, важно отметить, что нынешний ИИ, несмотря на свои успехи, пока не может полностью повторить творчество и интуицию человека. Он скорее обрабатывает информацию по заданным алгоритмам, чем по-настоящему понимает и создает что-то новое.

Г. С. Осипов полагает, что «искусственный интеллект выступает предметом компьютерных наук, а создаваемые на его основе технологии являются информационными технологиями, позволяющими совершать разумные рассуждения и действия с помощью вычислительных систем и иных искусственных устройств» [5, с. 8]. Автор подчеркивает, что ИИ является продуктом высокотехнологичных решений. Однако он упускает из виду такие аспекты, как этика и мораль.

Итак, все авторы связывают ИИ с когнитивными функциями человека, такими как мышление, логика, творчество и обработка информации. Каждый из перечисленных авторов смотрит на ИИ с разных углов, но все сходятся во мнении, что ИИ – это инструмент, который умеет имитировать, воспроизводить и дополнять человеческие когнитивные способности.

Что касается отличий, то одни авторы (например, Джон Маккарти) делают упор на творческое начало и свободу действий, другие (Г. С. Осипов) акцентируют внимание на технологии и техническом исполнении, третьи (И. Р. Бегишев и З. И. Хисамова) подчеркивают способность имитировать работу мозга, а четвертые (Л. С. Болотова) – на когнитивную обработку информации.

Интеграция ИИ в сферу преподавания иностранных языков способствует существенному повышению ее эффективности. Это доказывают публикации отечественных ученых.

По мнению Э. М. Карпович, «внедрение ИИ в сферу образования имеет большое количество преимуществ, среди которых прежде всего можно выделить индивидуализацию образования. Современные технологии, основанные на ИИ, способны адаптировать образовательный процесс под потребности каждого ученика, учитывая темпы усвоения материала, степень понимания и уровень знаний» [6].

Т. Л. Калинина, С. В. Щекочихина полагают, что, «создавая персонализированные образовательные траектории, ИИ предоставляет доступ к материалам, которые максимально соответствуют интересам и возможностям студентов» [7].

С. В. Ковальчук, И. А. Тараненко, М. Б. Устинова считают, что «использование ИИ может облегчить профессиональную деятельность преподавателя иностранного языка, сократив время на подготовку к занятиям, разработку и проверку заданий» [8].

О. М. Толстых, Е. В. Панасенко отмечают, что «ИИ обеспечивает последовательность и единообразие в учебных материалах, предоставляя учащимся одинаковый уровень качества и точности в разработанных материалах» [9, с. 392].

Современные технологии ИИ значительно расширяют горизонты в освоении иностранных языков [10, с. 131]. Классическое преподавание, ограниченное стенами учебного класса, не всегда предоставляет студентам возможность для языковой практики.

Технологии ИИ позволяют сделать обучение более индивидуальным. Об этом говорит и Л. А. Хамула. Она утверждает, что «ИИ может помочь в создании адаптивных образовательных программ, которые будут обладать способностью настраиваться в зависимости от уровня и потребностей каждого обучающегося» [11, с. 30].

Для студентов с начальным уровнем знания английского языка ИИ может предложить больше практических упражнений для укрепления основ [12, с. 133]. Для студентов с более продвинутым уровнем ИИ предложит более сложные задания и проекты для развития языковых навыков.

К. В. Устинова утверждает, что «на сегодняшний день существует множество инструментов и платформ, использующих искусственный интеллект для обучения английскому языку. К числу таких ресурсов относятся Duolingo, Busuu и Grammarly. Duolingo применяет адаптивные алгоритмы для создания персонализированных курсов, что позволяет учащимся эффективно продвигаться в изучении языка» [13, с. 21].

Чат-бот GPT предоставляет студентам ценный ресурс для самостоятельного обучения. Он предлагает возможности для отработки навыков чтения, письма, лексики и устной речи. Благодаря этому инструменту можно вести диалог с виртуальным собеседником и обмениваться вопросами и ответами.

Для формирования речевой компетенции, например в области грамматики, Н. В. Каржанова предлагает использовать ChatGPT. «Если вам необходимо попрактиковаться в грамматике, то вы можете попросить ChatGPT напомнить вам грамматическое правило или спросить у вас те или иные правила, которые вам необходимо повторить, попросить чат-бот озвучивать вам парадигму спряжения того или иного глагола по порядку следования местоимений или в случайном порядке с целью последующего перевода этой формы с одного языка на другой и автоматической проверкой, сгенерировать предложения, в которых фигурируют конкретные грамматические формы и т.д.» [14, с. 98].

Для формирования речевых навыков А. Г. Сайфолла рекомендует чат-боты и языковые ассистенты. «ИИ может быть использован для создания чат-ботов и языковых ассистентов, которые помогают учащимся практиковать язык в реальном времени. Например, Replika или Microsoft Language Understanding Intelligent Service (LUIS) могут быть настроены для обучения языку и поддержки в общении на иностранных языках» [15, с. 80].

Рассмотрим некоторые ИИ-платформы для обучения английскому языку. Наиболее распространенные приложения, такие как Rosetta Stone, Linguist, Duolingo адаптируются под уровень знаний студента и помогают «поставить» правильное произношение. Платформа Explain My Answer предоставляет студентам возможность взаимодействовать с ботом, который оценивает ответы, дает обрат-

ную связь и предлагает дополнительные материалы. Babbel предлагает интерактивные онлайн-курсы с использованием ИИ. Данная платформа распознает речь и корректирует произношение, сравнивая его с образцами записи носителей языка.

Заключение. Следует отметить, что приведенные примеры – это лишь небольшая часть из огромного множества современных инструментов для языкового обучения. Однозначно технологии ИИ кардинально трансформируют процесс изучения английского языка. Преподавателям и студентам необходимо адаптироваться к новым условиям и активно интегрировать технологии ИИ в учебный процесс. ИИ позволяет ускорить процесс обучения и улучшить языковые, речевые и социокультурные компетенции студентов. Данные технологии предоставляют больше возможностей для самостоятельного обучения и повышают уверенность обучающихся.

Для достижения существенного прогресса в изучении иностранных языков с помощью ИИ преподавателям необходимо поддерживать самостоятельную работу студентов, предлагая им ресурсы и разъясняя их применение. Пока рано делать окончательные выводы об эффективности ИИ в обучении иностранному языку, поскольку исследования находятся на начальной стадии. Тем не менее уже наблюдается повышенный интерес студентов к ИИ, их мотивация растет, а количество ошибок у тех, кто его использует, снижается.

Несомненно, у ИИ высокий потенциал, возможно, в будущем ИИ изменит подходы к преподаванию иностранных языков, открывая новые возможности. Однако необходимо взвесить все «за» и «против», а также оценить потенциальные риски, связанные с этим технологическим прорывом.

Библиографический список

1. Антонова Н. А. Применение искусственного интеллекта при обучении иностранному языку в системе высшего образования // Гуманитарные науки и образование. 2025. Т. 16, № 1 (61). С. 8–15.
2. McCarthy J. Recursive Functions of Symbolic Expressions and Their Computation by Machine, Part I // Communications of the ACM. 1960. Vol. 3, no. 4. P. 184–195.
3. Бегишев И. Р., Хисамова З. И. Искусственный интеллект и уголовный закон. М.: Проспект, 2022. 192 с.
4. Болотова Л. С. Системы искусственного интеллекта: модели и технологии, основанные на знаниях: учебник. М.: Финансы и статистика, 2012. 664 с.
5. Осипов Г. С. Искусственный интеллект: состояние исследований и взгляд в будущее // Новости искусственного интеллекта. 2001. № 1. С. 3–13.
6. Карпович Э. М. Применение искусственного интеллекта в обучении иностранным языкам // Филологический аспект: международный научно-практический журнал. Сер.: Методика преподавания языка и литературы. 2023. № 04 (21). URL: <https://scipress.ru/fam/articles/primenenie-iskusstvennogo-intellekta-v-obuchenii-inostrannym-yazykam.html>
7. Калинина Т. Л., Щекочихина С. В. Применение инструментов искусственного интеллекта в самостоятельном изучении иностранных языков // Мир науки. Педагогика и психология. 2025. Т. 13, № 2. URL: <https://mir-nauki.com/PDF/17PDMN225.pdf>
8. Ковальчук С. В., Тараненко И. А., Устинова М. Б. Применение искусственного интеллекта для обучения иностранному языку в вузе // Современные проблемы науки и образования. 2023. № 6. URL: <https://science-education.ru/ru/article/view?id=33000>
9. Толстых О. М., Панасенко Е. В. Потенциал искусственного интеллекта в языковом образовании: практические рекомендации для преподавателей // Горизонты образования: материалы IV Междунар. науч.-практ. конф., Омск, 20–21 апреля 2023 г. / отв. ред. Н. В. Чекалева. Омск: Омский гос. пед. ун-т, 2023. С. 391–393.

10. Игнатьева Т. С. Современный подход к обучению английскому языку студентов медицинских вузов // Современное высшее образование: вызовы времени и актуальные решения: материалы XVI Междунар. учеб.-метод. конф., Чебоксары, 25 октября 2024 г. Чебоксары: Чувашский гос. ун-т им. И. Н. Ульянова, 2024. С. 126–131.
11. Хамула Л. А. Потенциал технологий искусственного интеллекта в преподавании иностранного языка // Образование и проблемы развития общества. 2024. № 2 (27). С. 30–35.
12. Николаева Н. В. Проблемы обучения четырем видам речевой деятельности на иностранном языке // Межкультурная коммуникация и профессионально-ориентированное обучение иностранным языкам: сб. материалов Всерос. науч.-практ. конф., Чебоксары, 30 ноября 2023 г. Чебоксары: Чувашский гос. ун-т им. И. Н. Ульянова, 2023. С. 130–134.
13. Устинова К. В. Применение нейросети при обучении английскому языку // Образование и воспитание. 2025. № 4 (56). С. 18–24.
14. Каржанова Н. В. Роль искусственного интеллекта в преподавании иностранных языков // Актуальные проблемы общей теории языка, литературы, перевода, межкультурной коммуникации и методики преподавания иностранных языков: сб. ст. по материалам межрегион. науч.-практ. конф., Москва, 13 декабря 2023 г. Самара: Самарский ФИЦ РАН, 2024. С. 97–99.
15. Сайфолла А. Г. Использование инструментов искусственного интеллекта для повышения мотивации учащихся на занятиях // Иностранные языки: лингвистические и методические аспекты. 2024. № 49. С. 79–84.

CONTEMPORARY ENGLISH LANGUAGE TEACHING: THE REVOLUTION OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES

Nadezhda A. Antonova

I. N. Ulyanov Chuvash State University
15, Moskovsky pr., Cheboksary, Russia, 428000
nejda@rambler.ru

This article examines the role and importance of artificial intelligence (AI) technologies in English language teaching. Using various definitions, it concludes that modern technologies have the potential to significantly transform the process of learning foreign languages, making it more accessible, engaging, and effective. The author cites popular services and apps that demonstrate the potential for developing English language skills. It concludes that modern AI technologies accelerate the English language learning process, enhance motivation, and build learners' confidence.

Keywords: artificial intelligence, technology, English language, education, students, efficiency

ОЦЕНКА ЗНАНИЙ: ПРИРОДА БОЛЬШИХ ДАННЫХ В ОБРАЗОВАНИИ, МОДЕЛИ АНАЛИТИКИ РЕЗУЛЬТАТОВ ОБУЧЕНИЯ

Казаринова Наталья Леонидовна

Пермский государственный гуманитарно-педагогический университет
614990, Россия, г. Пермь, ул. Сибирская, 24
pmazarinova@pspu.ru

В статье рассмотрена трансформация традиционной системы оценки знаний под влиянием технологий больших данных, искусственного интеллекта и образовательной аналитики. Анализируется переход от разовых контрольно-измерительных процедур к непрерывному мониторингу и глубокому анализу образовательной деятельности. Исследуются ключевые источники образовательных данных, методы их обработки и аналитические модели. Особое внимание уделяется практическим аспектам реализации образовательной аналитики, а также информационному обеспечению программных продуктов.

Ключевые слова: оценка знаний, большие данные, образовательная аналитика, модели оценки знаний, педагогические измерения, искусственный интеллект

Введение. Традиционная система оценки знаний, основанная на экзаменационных баллах и стандартизированных тестах, долгое время являлась основным инструментом для измерения академической успеваемости. Такие подходы рассмотрены в классических работах И. Я. Лернера, М. Н. Скаткина, В. С. Аванесова, В. Н. Максимовой [1–4] и др.

Данные работы обосновывают основные параметры системы формирования знаний: контроль, обучающие функции, проверку и оценку знаний. В трудах авторы формулируют требования к качеству знаний обучающихся, к оценке знаний, работ учащихся в рамках учебной дисциплины. Однако такая оценка знаний обладает рядом существенных ограничений: фрагментарность, субъективность, запаздывающая обратная связь и ориентация на результат, а не на процесс.

Современная практика оценивания знаний, умений, навыков (ОЗУН) на всех этапах обучения активно реализуется с использованием различных инструментов информационных технологий. Модели расчета оценки ОЗУН и формирования оценочных средств рассмотрены в публикациях С. А. Бяшовой, И. Ю. Денисовой [5–7].

Дальнейшая разработка современных информационных подходов требует рассмотрения следующих требований: формирования информационного обеспечения данными изучаемой дисциплины, группы дисциплин; модель обработки информационного стека ОЗУН и модели формирования соответствия оценивающих информационных материалов стеку обучения ОЗУН; динамическая модель расчета и хранения оценки сформированности ОЗУН [8].

Целью данной статьи является анализ программных решений в части практической реализации информационного обеспечения оценки сформированности ОЗУН, использования методов расчета результатов, использования методов аналитики больших данных для комплексной, объективной оценки знаний.

Анализ проведен на основе работы, проведенных расчетов, регистрации сформированных баз данных: 1) ПРОФИЛЬ-Э: информационная система расчета реального профиля студентов (компетенции + трудовые функции) и сравнения с эталонным профилем по направлению подготовки (разработка 2022 г.); 2) Базы данных (БД) «Словарь характеристик профессиональных компетенций примерных рабочих программ по направлению и профилю подготовки» (344 765 характеристик); 3) БД «Профессиональные и образовательные компетенции ИТ-направления подготовки» [11]; 4) БД «Эталонные характеристики компетенций примерных рабочих программ основного общего образования» [12]; 5) Тренажер ОЗУН информационная система метрической оценки знаний оценки результатов основного общего образования (разработка 2025 г.).

Источники и природа образовательных больших данных. Образовательные большие данные характеризуются использованием действующих нормативов и образовательных стандартов.

- Нормативные образовательные требования к общему образованию: система Федеральных государственных образовательных стандартов начального основного образования и основного общего образования (ФГОС НОО, ФГОС ООО); нормативные образовательные требования к специальному и высшему образованию – система Федеральных государственных стандартов специального профессионального и высшего образования по направлениям (ФГОС СПО, ФГОС ВО).

- Системы управления обучением (LMS): Moodle, GetCourse, Prodamus.XL, CoreApp, SkillSpace. Фиксируют действия школьников студентов: просмотры образовательного контента, время, затраченное на материал, прохождение тестов, скачивание файлов.

- Адаптивные обучающие системы и образовательные игры (дополнение модели): (разрабатывается в ФГБОУ ВО, но не учитывается в данном исследовании) генерируют данные о каждой взаимодействии учащегося с контентом, включая правильные / неправильные ответы, используемые подсказки, стратегии решения задач.

- Комплексные данные системы выполненных работ и контрольных процедур: данные контрольных промежуточных и итоговых оценок; о поведении во время экзамена (движения глаз, активность в браузере, фокус внимания), а также биометрические данные (в перспективе).

- Коммуникационные данные (дополнение модели): активность в корпоративных сетях, чатах, работа в командах, отражающая уровень коммуникативных навыков.

Перечисленное информационное обеспечение в образовательных системах оценивания позволяет реализовать модели и методы оценки знаний. Данное информационное обеспечение вместе с накопленными оперативными данными используются для машинного обучения.

Методы и модели аналитики для оценки знаний. Аналитика использует следующие модели, которые позволяют оценить результаты обучения по различным образовательным программам.

В статье [9] разработана математическая модель матрицы системы профессиональных компетенций, которая позволяет проводить переход от расчета оценки

сформированности фрагментов системы (СПХ) через алгоритм заполнения матрицы покрытий к неравномерной шкале измерения термов.

Таблица 1

Матричное представление СПХ

Внешний уровень представления СПХ: $СПХ = \bigcup_{i=1}^n \Phi_i$	Промежуточный уровень представления СПХ: $\Phi_i = \bigcup PX_{ij}$	Внутренний уровень представления СПХ: $СПХ = \bigcup (ЗКПХ_{ijk} \cup ДКПХ_{ijl})$	
		ЗКПХ _{ijk} , где k – номер знаниевого компонента в структуре PX_{ij} , $k \in N$	ДКПХ _{ijl} , где l – номер деятельностного компонента в структуре PX_{ij} , $l \in N$
Фрагмент 1 / Этап 1	PX_{11}	$ЗКПХ_{111}, \dots, ЗКПХ_{11p_{11}}$	$ДКПХ_{111}, \dots, ДКПХ_{11t_{11}}$
	PX_{12}	$ЗКПХ_{121}, \dots, ЗКПХ_{12p_{12}}$	$ДКПХ_{121}, \dots, ДКПХ_{12t_{12}}$
	...	...	...
	PX_{1m_1}	$ЗКПХ_{1m_11}, \dots, ЗКПХ_{1m_1p_{1m_1}}$	$ДКПХ_{1m_11}, \dots, ДКПХ_{1m_1t_{1m_1}}$
Фрагмент 2 / Этап 2	PX_{21}	$ЗКПХ_{211}, \dots, ЗКПХ_{21p_{21}}$	$ДКПХ_{211}, \dots, ДКПХ_{21t_{21}}$
	...	...	...
	PX_{2m_2}	$ЗКПХ_{2m_21}, \dots, ЗКПХ_{2m_2p_{2m_2}}$	$ДКПХ_{2m_21}, \dots, ДКПХ_{2m_2t_{2m_2}}$
...	...	...	...
Фрагмент n / Этап n	PX_{n1}	$ЗКПХ_{n11}, \dots, ЗКПХ_{n1p_{n1}}$	$ДКПХ_{n11}, \dots, ДКПХ_{n1t_{n1}}$
	...	...	...
	PX_{nm_n}	$ЗКПХ_{nm_n1}, \dots, ЗКПХ_{nm_np_{nm_n}}$	$ДКПХ_{nm_n1}, \dots, ДКПХ_{nm_nt_{nm_n}}$

В табл. 1 рассмотрена матрица, где СПХ – перечень фрагментов Φ_i профессиональной сферы; промежуточный уровень – перечни профессиональных характеристик PX_{ij} , соответствующих фрагментам Φ_i , причем для каждого фрагмента перечни содержат различное количество характеристик PX_{ij} (если $i = 1$, то $j = \overline{1, m_1}, \dots$, если $i = n$, то $j = \overline{1, m_n}$; $\{n, m_1, \dots, m_n\} \subset N$); внутренний уровень представления матрицы СПХ раскрывает структуру PX_{ij} , которая представлена совокупностью матриц двух видов – «знаниевым компонентом PX_{ij} » (ЗКПХ_{ijk}, где k – номер знаниевого компонента в структуре PX_{ij} , $k \in N$) и «деятельностным компонентом PX_{ij} » (ДКПХ_{ijl}, где l – номер деятельностного компонента в структуре PX_{ij} , $l \in N$).

Модель (табл. 1) позволяет обеспечить единый подход к оценке заданных профессиональных характеристик по видам деятельности и осуществить динамический анализ результатов образовательного процесса.

В работе [10] реализована модель оценки сформированности образовательных и профессиональных компетенций (МОСОПК) на основе проведенных исследований в рамках государственного задания № 07-00080-21-02 от 18.08.2021 Министерства просвещения Российской Федерации. В разработке модели МОСОПК использованы работы Ф. А. Шродта, Дж. Проктора, Т. Саати, теории измерений по К. Шеннону.

На рис. 1 ФГОС 3++ – федеральный государственный образовательный стандарт; УК – универсальные компетенции; ОПК – общепрофессиональные компетенции; ПК – профессиональные компетенции; ТФ – трудовая функция; ПРП – примерная рабочая программа; РУП – рабочий учебный план; Д – дисциплина.




Рис. 1. Структурная модель формирования компетенции студента-педагога

В ИС ПРОФИЛЬ-Э проводится декомпозиция база эталонных характеристик студента педагогического вуза на коллекции эталонных характеристик: образовательные характеристики, универсальных компетенций; общепрофессиональные компетенции; трудовые функции; обобщенные трудовые функции.

Расчет эталонных характеристик формирования профиля студента педагогического вуза реализован в данной работе с использованием программного инструмента Word2vec. Полученные векторные представления слов использованы в обработке естественного языка и машинного обучения. В результате машинного обучения ПРОФИЛЬ-Э получены результаты эталонного профиля: семантическая информационная связанность для компетенций УК, ОПК и ТФ с учетом трудовых действий, необходимых знаний и умений. Эталонная БД использована для расчета фактически сформированных компетенция в пяти вузах Российской Федерации. База данных «Словарь характеристик профессиональных и образовательных компетенций по направлениям подготовки» прошла государственную регистрацию [11, 12].

Результаты использования методов в программных продуктах ПРОФИЛЬ-Э, Тренажер ОЗУН:

- проведена диагностическая аналитика для поиска причинно-следственных связей с помощью корреляционного анализа;

- реализована предиктивная аналитика для построения прогнозных моделей успешности изучения последующих дисциплин с использованием методов регрессионного анализа (деревья решений), кластеризации;
- реализована перспективная аналитика рекомендаций действий для достижения необходимых результатов обучения.

3. Модель педагогических измерений – метрологический подход. Обеспечение педагогических измерений способствует стандартизации и проходит этапы декомпозиции, например для ФГОС ВО по направлению, далее рабочий учебный план по направлению подготовки, на следующем этапе рассматривается содержание рабочих программ по дисциплине (РПД). Данный подход использован в ИС Тренажер ОЗУН.

Для стандартизации содержания рабочей программы необходимо рассмотреть подсистему «Дисциплина» на коды и информационные единицы, сформированные в РПД.

Модуль проектный, в который входят четыре дисциплины по РУП b090303_12_2024, профиль подготовки Искусственный интеллект (Проектная деятельности в ИТ сфере, Проектирование информационных систем по технологии клиент-сервер, Проектирование систем искусственного интеллекта, Проектирование и разработка мобильных приложений) содержит 4 подсистемы, 97 элементов по подсистемам (12; 22; 26; 37), т.е. всего 97 информационных единиц. Данная модель определяет число контрольных заданий для оценки сформированности компетенций по модулю, позволяет шкалу оценивания, рассчитать абсолютную и относительную погрешность оценивания определенного модуля, РУП, направления подготовки.

Заключение. Проведенный анализ демонстрирует, что современная оценка знаний эволюционирует в сторону сложных, интегрированных систем, сочетающих метрологические подходы, моделирование и подготовку и обучение инструментов ИИ для анализа больших данных. Приведенные решения подтверждают необходимость разработки систем непрерывного, многомерного и глубокого анализа образовательного процесса, что позволяет перейти от оценки узконаправленных знаний к комплексной оценке ОЗУН, компетенций, включая когнитивные, социальные и метапознавательные навыки.

Библиографический список

1. Качество знаний учащихся и пути его совершенствования / под ред. М. Н. Скаткина, В. В. Краевского. М.: Педагогика, 1978. 208 с.
2. Аванесов В. С. Композиция тестовых заданий: учеб. пособие. М.: Центр тестирования, 2002. 217 с.
3. Максимова В. Н. Актуальные проблемы дидактики: лекции. Л.: ЛГПИ, 1982. 48 с.
4. Бурдин Н. П. Методы учебной деятельности по И. Я. Лернеру и М. Н. Скаткину в дисциплине «Основы конструирования в дизайн-проектировании» // Научно-методический электронный журнал «Концепт». 2015. № S18. С. 31–35. URL: <http://e-koncept.ru/2015/75244.htm> (дата обращения: 06.09.2025).
5. Бояшова С. А. Статические исследования характеристик средств измерений // Апробация автоматизированной системы оценки качества подготовки учащихся по учебным предметам (начальная школа). 2 этап: учеб.-метод. описание / под общ. ред. С. А. Бояшовой. СПб., 2015. 48 с.
6. Денисова И. Ю., Макарычев П. П. Математические модели онтологии базы знаний информационной обучающей системы 1 // Онтология проектирования. 2012. № 3 (5). С. 62–78. EDN PCSNOH.

7. Kazarinova N. Interaction of generations: problems, conflicts, and opportunities // Russian Journal of Communication. 2013. Vol. 5, no. 2. P. 193–195.
8. Разработка цифрового профиля студента педагогического университета: унифицированная информационная система оценки сформированности компетенций: монография / Н. Л. Казаринова, Л. Р. Лизунова, М. Г. Мишакина и др.; под общ. ред. Н. Л. Казариновой. Пермь: ПГГПУ, 2022. 156 с.
9. Казаринова Н. Л., Мишакина М. Г., Симакина Н. И., Кудреватых В. А. Математическая модель многофакторного расчета профиля студента университета // Электронные информационные системы. 2022. № 3 (34). С. 91–100.
10. Казаринова Н. Л., Кудреватых В. А. Информационное обеспечение формирования цифрового профиля студента педагогического вуза // Электронные информационные системы. 2022. № 4 (35). С. 106–115.
11. Профессиональные и образовательные компетенции IT-направления подготовки (09.03.03, 09.03.02), реализуемые педагогическим вузом / Н. Л. Казаринова, В. А. Кудреватых, М. Г. Мишакина. Свид. о регистрации базы данных RU 2023620428, 01.02.2023. Заявка № 2022623623 от 12.12.2022.
12. Эталонные характеристики компетенций примерных рабочих программ основного общего образования / Н. Л. Казаринова, В. А. Кудреватых, М. Г. Мишакина. Свид. о регистрации базы данных RU 2023620427, 01.02.2023. Заявка № 2022623626 от 12.12.2022.

ASSESSMENT OF KNOWLEDGE: THE NATURE OF BIG DATA IN EDUCATION, ANALYTICAL MODELS OF LEARNING OUTCOMES

Natalya Leonidovna Kazarinova

Perm State Humanitarian and Pedagogical University
24, Sibirskaya Str., Perm, Russia, 614990
prmazarinova@pspu.ru

The article discusses the transformation of the traditional system of knowledge assessment under the influence of big data technologies, artificial intelligence, and educational analytics. It analyzes the transition from one-time control and measurement procedures to continuous monitoring and in-depth analysis of educational activities. Key sources of educational data, methods of their processing, and analytical models are explored. Special attention is given to the practical aspects of implementing educational analytics, as well as the information support of software products.

Keywords: knowledge assessment, big data, educational analytics, knowledge assessment models, educational measurements, artificial intelligence

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ФОРМИРОВАНИЯ ЧЕРНОВЫХ РЕЦЕНЗИЙ В МОДУЛЕ АВТОМАТИЗИРОВАННОГО РЕЦЕНЗИРОВАНИЯ НАУЧНЫХ ПУБЛИКАЦИЙ

Малявин Максим Юрьевич

Московский информационно-технологический университет –
Московский архитектурно-строительный институт МАСИ
129164, Россия, г. Москва, Волгоградский пр-т., д. 32, корп. 11
max-malyavin@bk.ru

Григорьев Сергей Георгиевич

Московский городской педагогический университет
129226, Россия, Москва, 2-й Сельскохозяйственный проезд, 4
grigorsg@yandex.ru

Рыбаков Даниил Сергеевич

Московский городской педагогический университет
129226, Россия, Москва, 2-й Сельскохозяйственный проезд, 4
rybakovds@yandex.ru

В статье представлена концепция применения технологий искусственного интеллекта для формирования черновых рецензий в модуле автоматизированного рецензирования научных публикаций. Предложенный подход не предполагает полной замены рецензента, но ориентирован на повышение эффективности его работы за счет автоматизированного формирования структуры и ключевых элементов чернового варианта рецензии.

Ключевые слова: искусственный интеллект, автоматизация рецензирования, языковые модели, рецензия, интеллектуальная поддержка, научные публикации

Введение. В последние годы в России наблюдается устойчивый рост публикационной активности научного сообщества [1]. В численном выражении тенденции свидетельствуют о росте до более 700 тысяч публикаций в 2024 г. Увеличение числа журналов, конференций и электронных площадок сопровождается значительным ростом объемов рукописей, направляемых на экспертизу. Это создает дополнительную нагрузку на редакционные коллегии и рецензентов, от работы которых во многом зависит качество научных публикаций и доверие к ним. Традиционный формат рецензирования, предполагающий исключительно ручную подготовку экспертных заключений, становится менее эффективным в условиях возрастающих требований к оперативности и объективности оценки.

Ранее автором настоящей статьи был предложен модуль автоматизации рецензирования научных публикаций, цель которого заключалась в стандартизации экспертной работы за счет использования специализированного набора критериев оценки [2]. Однако на текущем этапе исследования актуализируется необходимость дальнейшего развития данного подхода за счет интеграции технологий искусственного интеллекта (ИИ), позволяющих автоматизировать формирование

черновых рецензий и тем самым повысить эффективность деятельности экспертов. В связи с этим все большую значимость приобретает разработка концепций интеллектуальной поддержки редакционных процессов, в которых ключевая роль отводится анализу текста публикации и автоматизированному выделению основных элементов экспертного заключения. Подобные решения открывают новые возможности для ускорения рецензирования, повышения его качества и снижение влияния субъективных факторов.

Результаты и обсуждение. В условиях роста количества научных публикаций и постоянного расширения тематического поля исследовательской деятельности все острее проявляется проблема перегрузки экспертного сообщества. Несмотря на то что процесс рецензирования выполняет функцию контроля качества научного знания, его традиционная форма требует значительных временных затрат и зависит от индивидуальных особенностей каждого рецензента [3]. В связи с этим одним из наиболее перспективных направлений модернизации экспертных процедур становится использование искусственного интеллекта для автоматизации отдельных этапов подготовки рецензий [4]. Следует подчеркнуть, что речь не идет о полной замене рецензента интеллектуальной системой. Основная идея заключается в формировании чернового варианта рецензии, который в дальнейшем уточняется и дорабатывается экспертом. Такой подход позволяет разграничить механическую и аналитическую работу: алгоритм берет на себя первичную обработку текста статьи и подготовку структуры рецензии по заданным критериям, а рецензент осуществляет итоговый анализ, интерпретацию и оценку.

Суть предлагаемой концепции состоит в интеграции генеративных (языковых) моделей и алгоритмов анализа текста в существующий модуль автоматизации рецензирования. На основе введенных критериев (оригинальность, новизна, структура работы, качество источников, корректность методологии и т.д.) интеллектуальная система формирует черновой документ, в котором выделяются сильные стороны статьи, отмечаются потенциальные недостатки и формулируются рекомендации [5]. Такой черновик не имеет окончательного характера, но задает единообразный каркас экспертного заключения.

Применение ИИ в этом контексте открывает ряд преимуществ. Во-первых, существенно сокращается время, затрачиваемое на подготовку текста рецензии. Если в традиционном подходе на первичное оформление экспертного заключения может уходить несколько часов, то при использовании автоматизированного черновика эта стадия сокращается до 15–20 минут. Во-вторых, формируется более стандартизированная структура рецензий, что облегчает редакционную обработку и повышает сопоставимость заключений [6]. В-третьих, снимается часть рутинной нагрузки, что позволяет экспертам сосредоточиться на содержательной оценке статьи. Как результат, концепция применения ИИ для формирования черновых рецензий может рассматриваться как промежуточный этап между полной автоматизацией и традиционным экспертным анализом. Она объединяет преимущества цифровых технологий и профессионального опыта рецензентов, создавая гибридную модель, где машина обеспечивает скорость и стандартизацию, а человек – глубину и качество суждений (табл. 1).

Таблица 1

Концепция применения ИИ для формирования черновых рецензий

Параметр	Традиционный подход	Подход с применением ИИ	Преимущества нового подхода
Цель	Подготовка рецензии вручную полностью экспертом	Автоматическое формирование черновика с последующей доработкой	Снижение нагрузки на рецензента, ускорение процесса
Задачи	Анализ статьи, структурирование текста рецензии, формулировка рекомендаций	Генерация чернового текста по заданным критериям, выделение сильных и слабых сторон	Разделение рутинных и аналитических функций
Среднее время	2–3 часа	20–40 минут	Экономия до 70–80% времени
Идея	Индивидуальное и субъективное оформление рецензии	Стандартизированное автоматическое формирование структуры рецензии	Единообразие и формализация экспертных заключений
Преимущества	Гибкость, индивидуальность мнений	Скорость, стандартизация, интеллектуальная поддержка эксперта	Баланс между качеством экспертной оценки и эффективностью процедуры

На текущем этапе исследования актуализируется вопрос формализации задачи формирования черновых рецензий и определения возможных способов ее решения. Если ранее акцент делался на стандартизации процедуры рецензирования через специализированный модуль с набором критериев, то теперь возникает необходимость разработки концептуальной схемы применения искусственного интеллекта. Автором настоящей статьи предлагается следующая формализация и этапы решения задачи (рис. 1).

**Рис. 1. Формализация и этапы решения задачи**

Для того чтобы концепция применения искусственного интеллекта для формирования черновых рецензий приобрела более строгий характер, целесообразно описать ее в терминах формальной модели. Такая формализация позволяет отразить процесс преобразования текста статьи в структуру рецензии и выделить ключевые параметры эффективности системы.

1. Формализация статьи как множества признаков:

$$S \rightarrow F = \{f_1, f_2, \dots, f_n\}, f_i \in R,$$

где S – текст статьи, F – множество признаков, извлеченных моделью (новизна, актуальность, корректность методологии и т.д.).

2. Формирование черновой рецензии как функция генерации:

$$R_d = G(S, C, \theta),$$

где R_d – черновая рецензия, S – набор критериев оценки, C – генеративная модель, θ – ее параметры.

3. Оценка выигрыша по времени.

Пусть $T_{\text{трад}}$ – среднее время на подготовку рецензии традиционным способом, а T_{AI} – время при использовании ИИ. Тогда выигрыш по времени ΔT

$$\Delta T = \frac{T_{\text{трад}} - T_{AI}}{T_{\text{трад}}} * 100\%.$$

Например, если $T_{\text{трад}} = 180$ минут, а $T_{AI} = 30$ минут, то

$$\Delta T = \frac{180 - 30}{180} * 100\% = 83,3\%.$$

Представленная формализация показывает, что задача автоматизации рецензирования может быть выражена через набор признаков статьи, функцию генерации чернового текста и метрики эффективности. Это позволяет рассматривать концепцию не только как теоретическую идею, но и как основу для построения прикладных решений, ориентированных на ускорение и стандартизацию экспертных процедур.

В контексте представленной концепции ключевое внимание должно уделяться вопросам информационной безопасности. Особенность рецензирования научных публикаций заключается в том, что на этапе экспертной оценки обрабатываются материалы, содержащие как результаты оригинальных исследований, так и элементы интеллектуальной собственности, еще не прошедшие официальную публикацию. Утечка таких данных может нанести ущерб не только автору, но и издательским организациям, а также подорвать доверие к самой системе рецензирования. Одним из базовых требований, выдвигаемых к созданию инструмента автоматизированного формирования черновых рецензий, является развертывание собственной серверной инфраструктуры. Использование внешних облачных сервисов, пусть даже обладающих высокой производительностью, сопряжено

с рисками передачи конфиденциальных материалов за пределы контролируемой среды. В отличие от этого собственный сервер позволяет обеспечить замкнутый контур обработки информации, где все операции от загрузки статьи до генерации черновика рецензии выполняются внутри локальной или корпоративной сети.

Такое решение устраняет риски утечек данных, гарантирует соблюдение требований российского законодательства в области защиты информации (например, ФЗ-152 «О персональных данных» и ФЗ-149 «Об информации, информационных технологиях и о защите информации») и одновременно позволяет сохранять контроль над накопленным корпусом рецензий [7]. Более того, наличие собственного сервера обеспечивает дополнительную гибкость в обучении модели: используется только внутренняя база данных, сформированная на основе реальной практики рецензирования, что не только повышает качество итоговых текстов, но и исключает возможность использования информации сторонними поставщиками технологий. В результате ориентация на информационную безопасность и создание собственной серверной инфраструктуры становятся неотъемлемыми элементами концепции применения ИИ в автоматизации рецензирования. Это позволит объединить технологические преимущества интеллектуальных систем с требованиями к сохранности данных и защите авторских прав.

Заключение. Рассмотренная в статье концепция применения искусственного интеллекта для формирования черновых рецензий в модуле автоматизированного рецензирования научных публикаций демонстрирует перспективность интеграции интеллектуальных технологий в редакционно-экспертные процессы. В отличие от полной автоматизации, которая пока остается недостижимой в силу сложности задач экспертной оценки, предложенный подход ориентирован на создание промежуточного инструмента – генерацию чернового варианта рецензии с последующей доработкой экспертом. Ключевым преимуществом данного решения является сокращение временных затрат на подготовку рецензии, повышение стандартизации структуры экспертных заключений и снижение доли рутинной работы. При этом особое внимание уделяется вопросам информационной безопасности: развертывание собственной серверной инфраструктуры и использование локально обученной модели позволяют минимизировать риски утечки интеллектуальной собственности и обеспечить соблюдение требований законодательства в области защиты информации.

Формализация задачи через представление статьи как множества признаков, функцию генерации рецензии и метрики эффективности показывает, что данное направление может быть предметом дальнейших прикладных разработок. Интеграция языковой модели в уже созданный модуль автоматизации рецензирования открывает путь к формированию гибридной системы, в которой интеллектуальные алгоритмы поддерживают работу экспертов, а не заменяют их. В заключение следует отметить, что предложенная концепция послужит основанием для последующих исследований в области интеллектуализации редакционных процессов, а также создает практическую основу для разработки отечественных решений, способных повысить эффективность и качество рецензирования научных публикаций.

Библиографический список

1. Косычева М. А. Рецензирование как инструмент научной коммуникации // Health, Food & Biotechnology. 2021. № 1. С. 7–12.
2. Малявин М. Ю. Автоматизация рецензирования научных публикаций с использованием специализированного модуля. III Международная научно-практическая конференция «Взаимодействие естественного и искусственного интеллекта в образовательных системах». 2025.
3. Горбунова А. С., Засурский И. И., Трищенко Н. Д. Новые научные медиа: специфика платформ с открытым рецензированием // Вопросы теории и практики журналистики. 2021. № 1. С. 22–38.
4. Тамбовцев В. Л. Рецензирование в современных научных коммуникациях // Управление наукой: теория и практика. 2021. № 1. С. 35–54.
5. Спасенников В. В., Рытов М. Ю., Андросов К. Ю. Экспертная система поддержки принятия решений как средство повышения качества рецензирования статей в научном журнале // Эргодизайн. 2022. № 2 (16). С. 128–136.
6. Иванова Л. А. Искусственный интеллект при написании научных статей – положительный или вредоносный фактор? // Crede Experto: транспорт, общество, образование, язык. 2024. № 4. С. 6–17.
7. Малявин М. Ю. Основные атаки и методы защиты в контексте обеспечения безопасности современных web-приложений // Международный журнал информационных технологий и энергоэффективности. 2025. Т. 10, № 3 (53). С. 98–102.

THE USE OF ARTIFICIAL INTELLIGENCE FOR THE FORMATION OF DRAFT REVIEWS IN THE MODULE OF AUTOMATED REVIEW OF SCIENTIFIC PUBLICATIONS

Malyavin Maxim Yurievich

Moscow University of Information Technology –
Moscow Institute of Architecture and Civil Engineering MASI
Bldg 11, 32, Volgogradsky ave., Moscow, Russia, 129164
max-malyavin@bk.ru

Grigoriev Sergey Georgievich

Moscow City University
4, Vtoroy Selsk Khoziajstvenny proezd, Moscow, Russia, 129226
grigorsg@yandex.ru

Rybakov Daniil Sergeevich

Moscow City University
4, Vtoroy Selsk Khoziajstvenny proezd, Moscow, Russia, 129226
rybakovds@yandex.ru

The article presents the concept of using artificial intelligence technologies to generate draft reviews in the automated peer review module for scientific publications. The proposed approach does not involve a complete replacement of the reviewer, but is focus on improving the efficiency of his work through the automated formation of the structure and key elements of the draft version of the review.

Keywords: artificial intelligence, review automation, language models, review, intellectual support, scientific publications

ОТСЛЕЖИВАНИЕ ДИНАМИКИ ДВИЖЕНИЯ СТУДЕНТОВ В АУДИТОРИИ С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ YOLO

Муращенко Александр Романович

ФГБОУ ВО «Донецкий национальный технический университет»
283001, Россия, ДНР, г. Донецк, ул. Артема, 58
sasha.mur01@mail.ru

Федяев Олег Иванович

ФГБОУ ВО «Донецкий национальный технический университет»
283001, Россия, ДНР, г. Донецк, ул. Артема, 58
olegfedyayev@mail.ru

В статье описана разработка системы компьютерного зрения для обнаружения объектов и анализа их движения на примере студентов в аудитории. Система позволяет наблюдать в режиме реального времени за поведением студентов в аудитории с целью более глубокого интеллектуального анализа различных форм реакции студентов на организацию и тематику учебных занятий.

Ключевые слова: нейросетевые технологии, распознавание образов, нейронная модель YOLO, динамика объектов, контроль поведения студентов

Введение. Современное образование стоит на пороге революционных изменений благодаря передовым информационным технологиям. Особенно это связано с возможностями искусственного интеллекта (ИИ), который стимулирует преподавателей и обучающихся более активно применять его методы для своих потребностей и эффективного решения различных задач в образовательной сфере. Искусственный интеллект, безусловно, нужно правильно внедрять в учебный процесс, т.е. рассматривать его как технологического помощника, а не заместителя учителя [1].

Данное исследование затрагивает вопросы применения компьютерного зрения, как одного из продвинутых направлений ИИ, для улучшения проведения и планирования учебного процесса. Созданные системы компьютерного зрения уже успешно используются в приложениях, ориентированных на безопасность: отслеживать движение в определенных зонах, контролировать большие скопления людей и т.д. Кроме автоматической регистрации студентов при входе в аудиторию актуальной задачей является видеонаблюдение за студентами в аудитории во время занятия [2]. Компьютерное зрение и методы машинного обучения позволяют анализировать информацию из визуальных данных с целью контроля поведения учащихся, оценивать уровень вовлеченности учащихся во время занятия, собирать данные об их эмоциональном состоянии.

Основная цель представленной работы – разработка и исследование системы для обнаружения заданных объектов на видеопотоке и анализа динамики их движения. Распознавание объектов на видеопотоке осуществляется с помощью нейронной модели YOLO, которая основана на передовых достижениях

в области глубокого обучения и компьютерного зрения, предлагая беспрецедентную производительность с точки зрения скорости и точности [3]. Такая система позволит на учебных занятиях наблюдать за поведением студентов в аудитории, анализировать видео и формировать для преподавателя различную аналитику о проведении занятий.

Постановка задачи распознавания заданных объектов на изображении. Пусть на вход поступает изображение $I = R^{N \times N \times C}$, где N – количество пикселей в изображении; C – цвет пикселя на координате. Список классов $K = \{O1, O2, \dots, Om\}$, где m – количество распознаваемых объектов. Также дан порог уверенности E . Необходимо найти функцию F , которая возвращает для каждого объекта на изображении: класс объекта, координаты ограничивающей рамки, уровень уверенности. Функция F вычисляется по формуле

$$F(I, E) = \{(c_i, b_i, p_i) | p_i \geq E\}_{i=1}^k,$$

где $c_i \in K$ – класс объекта, $b_i = (x_{min}, y_{min}, x_{max}, y_{max})$ – координаты ограничивающей рамки, p_i – уверенность предсказания модели, k – количество обнаруженных объектов.

Функция F состоит из трех подфункций: классификация объектов, локализация объектов, фильтрация погрешности.

Классификация объектов возвращает вектор уверенности (p_i) для каждого класса и вычисляется по формуле

$$f_{class} : I \rightarrow [0,1]^m.$$

Локализация объектов возвращает координаты ограничивающих рамок для каждого обнаруженного объекта и вычисляется по формуле

$$f_{loc} : I \rightarrow R^{x_{min}, y_{min}, x_{max}, y_{max}}.$$

Фильтрация погрешности удаляет все объекты с уверенностью ниже, чем E и вычисляется по формуле

$$f_{filter}(\{(c_i, b_i, p_i)\}, E) = \{(c_i, b_i, p_i) | p_i \geq E\}.$$

Для выполнения задачи необходимо построить функцию F , которая соответствует поставленным условиям.

Проектирование программы для распознавания заданных объектов с использованием нейронной сети YOLO. Система состоит из трех блоков: обычного распознавания, сегментации, оценка позы.

Алгоритм системы показан на примере блока «оценка позы». Оценка позы – это задача, которая заключается в определении местоположения определенных точек на изображении, обычно называемых ключевыми точками. Ключевые точки могут представлять собой различные части объекта, такие как суставы, ориентиры или другие отличительные особенности. Расположение ключевых точек обычно представляется в виде набора двумерных $[x, y]$ или 3D $[x, y, visible]$ координат [4]. Алгоритм оценки позы показан на рис. 1.

На вход поступает изображение из выбранного источника. Далее передаются параметры, которые были получены при обучении (классы, признаки). Пользователь выбирает параметры. После этого происходит захват изображения с помощью библиотеки CV. Далее происходит два параллельных процесса. При детектировании модель разделяет изображение на разные размеры, чтобы получить местоположение каждого возможного объекта. С каждой части разделенного изображения извлекаются признаки и местоположение ограничивающих рамок. Проходит объединение всех признаков, полученных с различных слоев и прогнозирование классов. Далее происходит прогнозирование областей ограничивающих рамок, их координаты. Для оценки позы модель находит конечности каждого человека и формирует тензор данных. Затем для каждой найденной ограничивающей рамки происходит привязка предсказанных ключевых точек. После обработки всего изображения формируется результат и изображение с итоговыми данными.




Рис. 1. Алгоритм оценки позы с помощью нейронной сети модели YOLO

Для определения движения объекта между кадрами использовался метод трекинга Bot-Sort. Данный метод и его компоненты могут быть легко интегрированы в другие трекеры для отслеживания-обнаружения [5].

Применение нейронной сети при работе со студентами в аудитории. Цифровизация контроля проведения учебных занятий включает в себя использование технологий для автоматизации и улучшения мониторинга учебного процесса. Цифровизация поможет анализировать вовлеченность студентов во время учебного процесса в реальном времени, снижать нагрузку на преподавателей, автоматизировать некоторые процессы, в том числе, отметку посещаемости.

Эксперименты проводились на следующей конфигурации.

- Процессор: Intel i3-1005G1(8 потоков, 2 ядра).
- Видеокарта: nVidia GeForce MX330(2 Гб графической памяти).
- Оперативная память: 8 Гб.

Все нейросетевые модели обучены на датасете COCO, который содержит 80 классов объектов.

При движении отдельных частей тел можно использовать оценку позы, которая полностью передает координаты каждой части тела. Оценка позы показывает и передает координаты конкретных частей тела: глаз, ушей, носа, плеча, локтя и т.д. На рис. 2 показан результат работы нейросетевой модели для оценки позы на примере студентов в аудитории.




Рис. 2. Работа нейросетевой модели для оценки позы студентов в аудитории

Благодаря координатам частей тела можно реализовать алгоритм для обнаружения нестандартных движений при распознавании на видеопотоке. На рис. 3 показана работа алгоритма оценки позы и выделения человека, который поднял руку на фотографии. Алгоритм по положению руки определяет, какую именно руку поднял человек. Каждому человеку присвоен идентификатор. Если человек поднял руку, то алгоритм покажет над ограничивающей рамкой какую именно.

Заключение. В данной работе была построена система, выполняющая обработку простого движения студентов на примере поднятия руки.

Разработанная система точно обнаруживает объекты на статичном кадре, запоминает движущиеся объекты на видеопотоке. Использование модели YOLO и алгоритма трекинга Bot-Sort позволяет отследить динамику движения объектов. Применение модели YOLO возможно при разных условиях установки камеры. Модель продемонстрировала отличную работу при обработке видеопотока в реальном времени, показав минимальное время обработки.




Рис. 3. Работа алгоритма с использованием оценки позы для определения положения руки

На основании полученных результатов можно сделать вывод, что, система работает корректно и позволяет расширить виды анализа динамики объектов. В частности, система позволит наблюдать в реальном масштабе времени за поведением студентов в аудитории с целью более глубокого интеллектуального анализа различных форм реакции студентов на организацию и тематику учебных занятий.

Библиографический список

1. Усова С. Н., Попова А. В. Искусственный интеллект в помощь педагогу: первые практические результаты // Шамовские чтения: сб. ст. XVI Междунар. науч.-практ. конф.: в 2-х т., Москва, 25 января – 03 февраля 2024 г. М.: Научная школа управления образовательными системами, 2024. С. 419–425. EDN HESKXD.
2. Суханов А. А., Баев Д. Э., Федяев О. И. Видеорегистрация присутствия студентов в аудитории на основе нейросетевого распознавания лиц // Информатика и кибернетика. 2024. № 3 (37). С. 45–50. EDN HSAQIQ.
3. docs.ultralytics.com – Документация Ultralytics. Описание модели YOLO. URL: <https://docs.ultralytics.com/ru/#where-to-start>
4. docs.ultralytics.com – Документация Ultralytics. Оценка позы. URL: <https://docs.ultralytics.com/ru/tasks/pose/>
5. Муращенко А. Р., Федяев О. И. Оценка скорости движения объекта с помощью нейросетевой модели YOLO // Программная инженерия: методы и технологии разработки информационно-вычислительных систем (ПИИВС-2024): сб. материалов и докл. V Междунар. науч.-практ. конф, Донецк, 27–28 ноября 2024 г. Донецк: Донецкий национальный технический университет, 2024. С. 193–199. EDN SCHGAJ

TRACKING THE DYNAMICS OF STUDENT MOVEMENT IN THE CLASSROOM USING THE YOLO NEURAL NETWORK

Alexandr R. Murashchenko

Donetsk National Technical University,
58, Artema Str., Donetsk, DPR, Russia, 283001
sasha.mur01@mail.ru

Oleg I. Fedyaev

Donetsk National Technical University,
58, Artema Str., Donetsk, DPR, Russia, 283001
olegfedyayev@mail.ru

The article describes the development of a computer vision system for object detection and motion analysis, using the example of students in a classroom. The system allows for real-time observation of student behavior in the classroom to enable a more in-depth intellectual analysis of various forms of student reactions to the organization and subject matter of educational sessions.

Keywords: neural network technologies, pattern recognition, YOLO neural model, object dynamics, student behavior monitoring

ОПЫТ ИСПОЛЬЗОВАНИЯ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ ПРИ КОНСТРУИРОВАНИИ РАСПИСАНИЯ ДЛЯ СРЕДНЕГО ПРОФЕССИОНАЛЬНОГО ОБРАЗОВАТЕЛЬНОГО УЧРЕЖДЕНИЯ

Ощепков Александр Олегович

Кузаев Айдар Файзуллович

Пермский государственный гуманитарно-педагогический университет

614990, Россия, г. Пермь, ул. Сибирская, 24

ochepkov_aleks@mail.ru

kuzaev@pspu.ru

В статье описывается использование искусственного интеллекта, а именно LLM-моделей, при составлении и корректировке расписания учебных занятий для студентов средних профессиональных учреждений на примере КГАПОУ «Пермский авиационный техникум им. А. Д. Швецова». Для проведения исследований выбираются большие языковые модели GigaChat и DeepSeek. Первая модель разработана ПАО «Сбербанк», вторая – китайской компанией, специализирующейся на разработке интеллектуальных систем. Полученные в данной работе результаты свидетельствуют о том, что генеративный искусственный интеллект не в состоянии полностью автоматизировать процесс формирования расписания и требуется вмешательство диспетчера расписания учебной части образовательной организации.

Ключевые слова: большие языковые модели, LLM-модель, генеративный искусственный интеллект, расписание занятий, промпты для нейронной сети

Введение. Качество подготовки будущих специалистов и эффективность использования научно-педагогического потенциала профессионального образовательного учреждения зависит от уровня организации учебного процесса. Расписание занятий регламентирует труд преподавателей и существенно влияет на их творческую отдачу. Экономический эффект от оптимально составленного расписания приводит к снижению затрат. Следует отметить, что составление расписания является достаточно сложной, многокритериальной задачей, так как учебный процесс многообразен и интересы участников тоже разные. В работе [1] авторов рассматриваются разработка, тестирование и внедрение информационной системы для составления расписания учебных занятий в профессиональном образовательном учреждении «Пермский авиационный техникум им. А. Д. Швецова» в рамках выполнения выпускной квалификационной работы бакалавра на кафедре прикладной информатики, информационных систем и технологий ПГГПУ. В данной статье представлены результаты попытки внедрения в эту информационную систему искусственного интеллекта – использование больших языковых моделей [2] при генерации расписания и удалении так называемых «окон» между парами.

Описание предметной области и постановка проблемы. Составление расписания любого образовательного учреждения напоминает игру в «Тетрис»,

где существуют свои законы и правила. Составление расписания обычно начинается с изучения следующих документов:

- графика обучения каждой группы (недели обучения, периоды учебной и производственной практики, сессии и каникулы);
- учебного плана (предметы и количество часов, отведенные на лекции и практические занятия);
- нагрузки преподавателей (объем часов, закрепленный за дисциплиной, преподавателем и группой).

Эти документы регламентируют главные правила и накладывают основные ограничения при составлении расписания. Безусловно, кроме этого, нужно учитывать и другие факторы, например:

- занятость преподавателя (отвести или забрать ребенка из садика);
- болезнь преподавателя;
- занятость аудитории, или попросту отсутствие необходимого количества рабочих мест для всех студентов группы;
- проведение дополнительных консультаций для групп преподавателями;
- внутренние мероприятия образовательной организации (выдача банковских карт, прохождение медицинской комиссии и т.д.).

Расписание – это словно живой организм, который меняется каждый день, и грамотность его составления зависит от верного расположения «кирпичиков» диспетчером учебной части. Диспетчеру необходимо постоянно держать под рукой все регламентирующие документы, а также дневник с записями, в котором содержится информация на конкретный день, поскольку хранить это все в голове невозможно.

В связи с существующей огромной нагрузкой, руководством Пермского авиационного техникума им А. Д. Швецова, было принято решение разработать информационную систему, упрощающую конструирование расписания для обучающихся групп. Разработанная система [1] позволяет учитывать при составлении расписания различные специальности, учебные планы, группы, обычные дисциплины, дисциплины специальности, дисциплины учебных планов, график учебного процесса, занятость аудиторного фонда, нагрузки преподавателей, время проведения консультаций, а также конструировать основное расписание по семестрам и формировать листы замен.

Информационная система также имеет функциональные возможности для импорта следующих документов, таких как график учебного процесса, учебные планы и нагрузки преподавателей. Позволяет формировать отчеты по проведенным часам и отслеживать количество отведенных часов по группам и преподавателям. Она также уведомляет о том, что преподаватель находится на больничном или не может провести занятие в связи с занятостью. ИС имеет проверки на вместимость группы в аудиторию, а также занятость или вывод аудитории из образовательного процесса. Однако разработанная информационная система лишь помогает в конструировании расписания, а не составляет его самостоятельно, что требует присутствия оператора, и как результат, не защищает от ошибок, связанных с человеческим фактором.




Рис. 1. «Окно» в расписании преподавателя

Анализ текущего расписания показывает, что у некоторых преподавателей в расписании могут находиться «окна» (рис. 1) – незанятые промежутки между учебными занятиями. Следует заметить, что это позволительно для преподавателей, которые совмещают преподавание с другими должностями, например, являются заведующими отделением или сотрудниками учебной части, воспитателями. В том случае, когда преподаватель не имеет дополнительной занятости, это является серьезным нарушением в составлении расписания. Для решения выявленной проблемы необходимо изменить расписание таким образом, чтобы убрать «окна» в расписании преподавателя.



Рис. 2. Проблемы, возникающие при изменении расписания

Однако любое изменение в расписании одной группы может повлечь за собой изменения в других группах. Так, например, изменив расписание для преподавателя И. И. Иванова, исключив «окно» у него в занятиях, информационная система уведомляет о занятости аудитории, в которой проводится занятие другой группой. При этом появляется «окно» у другого преподавателя – П. П. Петрова (рис. 2).

Метод решения проблемы и результаты. Для решения выявленной проблемы предлагается использовать LLM-модели, которые должны проанализировать существующее расписание, и изменить порядок занятий таким образом, чтобы исключить «окна» в расписании преподавателей. В экспериментах используются две популярные большие языковые модели: GigaChat [3] и DeepSeek [4]. GigaChat – нейросетевая модель Сбера, которая умеет отвечать на вопросы и вести диалог, писать код и создавать изображения. DeepSeek – нейронная сеть, разработанная одноименной китайской компанией. В отличие от большинства остальных решений, представленных на рынке, ее преимущество заключается в том, что она абсолютно бесплатна. Также отсутствуют ограничения по количеству и тематике запросов.

В первую очередь необходимо сформировать данные в расписании таким образом, чтобы это было понятно искусственному интеллекту. Для этого нужно сформировать файл данных в JSON-формате (стандартный текстовый формат для представления структурированных данных на основе синтаксиса объекта [5]). JSON-файл содержит всю информацию, предварительно обезличенную: номер пары, код дисциплины, код преподавателя, код аудитории, код группы и др.

Далее создается промпт (запрос с целью получить желаемое изображение или текст [6], в данном случае, сгенерированный нейросетью файл) для используемой модели, и предоставляется ей подготовленный JSON-файл. Вначале используется следующий промпт:

«Есть массив преподавателей, у которого указаны занятия (Pairs), в каждом занятии указана дисциплина (Discipline), аудитория (Audience) и номер занятия (PairNumber). Измени занятия преподавателей, у которых есть «окна», так, чтобы окон не было. Аудиторию оставь ту же самую. Дублирование занятий удалять нельзя, поскольку занятие проводится сразу для двух групп одновременно. Ответ представь в формате JSON»

Обобщенные результаты анализа ответов на запросы представлены в табл. 1.

Таблица 1

Результаты экспериментов

Критерий	GigaChat	DeepSeek
Время, затраченное на генерацию ответа	8 минут 53 секунды	5 минут 23 секунды
Отсутствие в расписании «окон» у преподавателей	Присутствуют, но в меньшем объеме	Присутствуют, но в меньшем объеме
Отсутствие «окон» у групп	Присутствуют	Присутствуют
Отсутствие некоторых занятий у групп	Некоторые занятия были удалены	Некоторые занятия были удалены

Как видно из таблицы, используемые языковые модели при решении поставленной задачи удалили из расписания некоторые пары, что недопустимо. Формулируем уточняющий промпт, добавляя дополнительное условие:

«Запрещено удалять самопроизвольно занятия из групп, количество занятий должно остаться неизменным»

Теперь искусственный интеллект выдает нужное количество занятий, которое изначально было представлено в JSON-файле. Однако при более подроб-

ном анализе ответа, обнаруживается, что ИИ ставит несколько дисциплин в одной аудитории и в одинаковое время (рис. 3).

```
{
  "Id": "252",
  "Pairs": [
    {"Discipline": 695, "Audience": 248, "PairNumber": 1, "Group": 22}
  ]
},
{
  "Id": "9",
  "Pairs": [
    {"Discipline": 691, "Audience": 248, "PairNumber": 1, "Group": 22}
  ]
}
```

Рис. 3. Наложение разных дисциплин в расписании

Добавляем новое правило:

«У одной и той же группы не могут быть одновременно две дисциплины в рамках одной и той же пары»

Несмотря на сформулированное дополнительное правило, ИИ не смог справиться с описанной проблемой: наложение дисциплин в итоговом результате сохранилось.

Еще одна проблема, которая возникла при генерации расписания использованными языковыми моделями, состоит в том, что у учебных групп имеются «окна» в расписании. Добавлением нового ограничения (***«Группа не должна иметь окон между занятиями»***) эту проблему также не удастся решить.

Описанные результаты позволяют сформулировать некоторые выводы. В сгенерированном ИИ расписании:

- присутствуют «окна» у преподавателей;
- происходит наложение дисциплин друг на друга;
- преподаватель может вести несколько занятий одновременно в разных группах;
- существуют «окна» в расписании групп.

Заключение. Полученные в данной работе результаты свидетельствуют о том, что большие языковые модели не в состоянии полностью автоматизировать процесс формирования учебного расписания. При составлении расписания учебных занятий возникают не преодолимые искусственным интеллектом трудности, которые напрямую не связаны с промпт-инжинирингом. Требуется вмешательство диспетчера в сгенерированное расписание и окончательная доработка в «ручном» режиме.

Библиографический список

1. Ощепков А. О., Кузаев А. Ф. Опыт разработки, тестирования и внедрения информационной системы в рамках выполнения квалификационных работ при подготовке ИТ-специалистов на факультете информатики и экономики ПГГПУ // Наука и образование в обеспечении устойчивого развития человеческого потенциала в условиях перехода к цифровой экономике: материалы XII Междунар. науч.-практ. конф., Пермь, 17–18 апреля 2025 г.: в 2 т. Т. 2 / ред. кол.: В. П. Пфлюг, Е. Б. Аликина, А. Ю. Скорнякова, А. А. Носков. Пермь: ПГГПУ, 2025. С. 118–126. URL: <https://nauka-pspu.tilda.ws/>

2. Большие языковые модели (LLM) в задачах. URL: <https://habr.com/ru/articles/775870/>
3. GigaChat: знакомство с нейросетевой моделью. URL: <https://courses.sberuniversity.ru/llm-gigachat/1/1/2>
4. Что такое DeepSeek и на что способна китайская нейросеть. URL: <https://habr.com/ru/companies/x-com/articles/878218/>
5. Работа с JSON. URL: https://developer.mozilla.org/ru/docs/Learn_web_development/Core/Scripting/JSON
6. Что такое промпт, как правильно его составить. URL: <https://www.unisender.com/ru/glossary/chto-takoe-prompt/>

EXPERIENCE USING LARGE LANGUAGE MODELS WHEN DESIGNING SCHEDULES FOR SECONDARY VOCATIONAL EDUCATIONAL INSTITUTIONS

Alexander O. Oshchepkov

Aydar F. Kuzaev

Perm State Humanitarian-Pedagogical University

24, Sibirskaya Str., Perm, Russia, 614990

oshchepkov_aleks@mail.ru

kuzaev@pspu.ru

The article describes the use of artificial intelligence, namely LLM models, in the preparation and adjustment of the schedule of training sessions for students of secondary vocational institutions using the example of the Perm Aviation Technical School named after A. D. Shvetsov. The large language models GigaChat and DeepSeek are selected for research. The first model was developed by Sberbank, the second by a Chinese company specializing in the development of intelligent systems. The results obtained in this work indicate that generative artificial intelligence is not able to fully automate the scheduling process and requires the intervention of the schedule manager of the educational part of the educational organization.

Keywords: large language models, LLM model, generative artificial intelligence, lesson schedule, neural network promptings

СЕРВИС БЫСТРОЙ ОЦЕНКИ ПРОФЕССИОНАЛЬНОГО ПОТЕНЦИАЛА ЧЕЛОВЕКА

Сичинава Зураби Иродиевич

ООО «НВ-Эмоции»

614089, Россия, г. Пермь, ул. Самаркандская, д. 94, оф. 23

sichinava@realnewvision.ru

В статье представлено описание сервиса «Профотбор будущего» на основе технологий компьютерного зрения и искусственного интеллекта, предназначенного для оптимизации процесса первичного профилирования соискателей при поиске работы. В основе решения – аналитическая система, моделирующая мышление эксперта по работе с персоналом на основе биометрического анализа изображений. Сервис «Профотбор будущего» внедрен и используется в 30 центрах занятости Пермского края.

Ключевые слова: искусственный интеллект, нейросетевые технологии, управление персоналом, оптимизация массового поиска персонала, профиль личностных компетенций, определение показателей задатков и способностей, оценка профессионального потенциала человека

Введение. Методы оценки и профилирования персонала – актуальная тематика, обусловленная необходимостью новых подходов к кадровой политике и управлению персоналом.

На данный момент современные компании заинтересованы в сохранении и развитии своего персонала и активно борются с текучестью персонала. Основные проблемы компаний в области управления персоналом и кадровой политики:

1) традиционные инструменты профилирования (проведение личных интервью и/или выполнения длительных диагностических тестов) требует много времени, соискателям не нравятся долгие процедуры анкетирования;

2) компании заинтересованы в подборе персонала не только согласно имеющемуся опыту работы, но и по личным качествам человека. Также немаловажным является подбор нового сотрудника в коллектив с учетом психологических профилей текущих сотрудников коллектива;

3) необходимы инструменты для проведения регулярных «быстрых» скрининговых тестирований.

Сервис «Профотбор будущего» предлагает технологически новый способ оценки и профилирования персонала, основанный на алгоритмах компьютерного зрения. Для функционирования данного способа требуется только фотоизображение человека.

Основные преимущества данного способа:

- скорость работы (время диагностики сокращается с 2–3 часов до нескольких минут);
- простота использования (для выполнения диагностики не требуется участия высококвалифицированного специалиста).

Научно-технический подход, использованный при разработке сервиса. Существует достаточно много попыток по решению задачи определения психо-

типа человека с использованием нейронных сетей, классифицирующих человека по психотипам на основе фотоизображения (начиная от наиболее простой классификации на экстравертов и интровертов до более сложных классификаций психотипов). В основе данных нейросетей лежит «категорийный подход». Например, при подготовке обучающего множества готовится определенное количество фотографий экстравертов и такое же количество фотографий интровертов, результатом работы алгоритмов является один из двух психотипов.

Отличительные особенности научно-технического подхода, предлагаемого в данном проекте, следующие.

1. Классификация выполняется в два этапа: сначала определяются биометрические параметры фотоизображения затем они интерпретируются для решения различных задач.

2. Нейросетевые алгоритмы применяются только для анализа изображений и выявления биометрических параметров.

Такой подход позволяет реализовать гибкий подход к диагностике и использовать выявленные параметры с учетом специфики каждой конкретной прикладной задачи. В отличие от «категорийного» подхода не требуется огромного количества данных (фотоизображений) для обучающего множества.

3. Интерпретация биометрических параметров, выполняется на основе существующих исследований в области визуальной психодиагностики и физиогномики и представляют собой экспертную сеть для каждой прикладной задачи. При этом возможны различные комбинации вариантов интерпретации, например проведение диагностики сразу по двум различным экспертным методикам.

Предложенный подход опирается на фундаментальный труд одного из ведущих деятелей позднего Просвещения – Иоганна Гердера. Книга Иоганна Гердера входит в программу высшего гуманитарного образования. В работе Гердера осмысляются закономерности внешности, быта и нравов отдельных этносов, с опорой на «чистые» признаки (до смешения этносов). На сегодняшний день каждый человек – это потомок нескольких этносов, что проявляется как в общем лице, так и в отдельных элементах лица. Разнообразие лиц - результат сохранения совокупности древних генетических кодов успешных, и потому устойчивых, реакций этноса на внешнюю среду. Опора на эти коды успеха дала основу для создания технологии выявления набора природных талантов отдельно взятого человека. Аналогичными исследованиями занимался и создатель всемирно известного «цветового теста Люшера» – Макс Люшер. Ученый описывал личность человека далеко за рамками только цветовой диагностики: в работах автора есть материалы наблюдений и анализа внешнего облика человека, его жилья и атрибутов обстановки. Автор провел явные параллели между личностными предпочтениями и внешними проявлениями людей. В дополнение к базовой теории мы использовали результаты исследований в области физиогномики и психологии современных специалистов-практиков (В. И. Тараненко, В. В. Пономаренко, М. Могильнер, М. Б. Ямпольский, Ю. В. Рядчикова), эти исследования преимущественно основаны на статистике наблюдений и личном опыте авторов.

Технические особенности разработки сервиса. Разработка и тестирование сервиса выполнялось совместно со специалистами Пермского центра заня-

тости в рамках федеральной программы модернизации центров занятости. Для обучения нейронной сети использовались данные тестирований реальных людей, которые обращались в центр занятости и проходили тестирование по традиционным методикам (профориентационные тестирования).




Рис. 1. Интерфейс сервиса

В рамках разработки сервиса были реализованы следующие основные функции сервиса.

1. Алгоритм технического анализа изображений. Алгоритм предназначен для анализа изображений и выявления биометрических параметров человека на основе фотоизображения.

В рамках подготовительных исследований были выбраны 40 параметров необходимых для работы сервиса и обучены нейронная сеть, определяющая данные параметры. Примеры параметров: форма лица (овал, прямоугольник, квадрат), соотношения конкретных параметров лица человека (отношения ширины лица к высоте лица), расположение глаз, бровей и т.п.

2. Разработана технология интерпретации результатов технического анализа изображений. В рамках данного сервиса за основу взята методика «семь радикалов». Технически технология интерпретации представляют собой несколько экспертных систем (для каждой формы-заключения используется отдельная экспертная система).

3. Результаты интерпретации реализованы в виде форм-заключений:

- «Ф-1 Профессиограмма» – рекомендуемые профессии согласно природным склонностям (рис. 2);
- «Ф-2 Профвариативность» – выявление выраженных направлений профессиональной деятельности;
- «Ф-3 Рекомендации по взаимодействию» – для профилактики негативных ситуаций, содействия долговременному сотрудничеству;

- «Ф-4 Экспресс-диагностика личности» – выявление природных задатков и склонностей (рис. 3).

▶ Просмотр заключения

Профессиограмма

Направление деятельности	Характеристики	%
ОРГАНИЗАТОРЫ, ПРЕДПРИНИМАТЕЛИ	Активность, наблюдательность, находчивость, предприимчивость, организаторские способности, умение влиять на значимых людей	26
КОНСУЛЬТАНТЫ, ПОМОЩНИКИ, ПРОДАВЦЫ, КОММУНИКАТОРЫ, МИРОТВОРЦЫ, ВОСПИТАТЕЛИ, УЧИТЕЛЯ	Гуманность, эмпатия, ориентированность на социальные нормы, коммуникабельность, отзывчивость	24
КОНСТРУКТОРЫ, ТЕХНОЛОГИ, ЮРИСТЫ, БУХГАЛТЕРЫ	Пунктуальность, аккуратность, последовательность, документооборот, работа с графиками, чертежами, цифрами	21
ЭТИКИ, ГУМАНИТАРИИ, ИССЛЕДОВАТЕЛИ, ПРЕПОДАВАТЕЛИ (ГУМ.)	Независимость во взглядах, новаторство, оригинальность мышления, осознанность, целеустремленность	29
Сводная характеристика: Технические: 38 %, Гуманитарные: 42 %, Естественнонаучные: 19 %		
Организаторские способности: Организатор: 56 %, Исполнитель: 44 %		
Способность к обучению: 64 %		
Тип занятости: Самостоятельный бизнес: 40 %, По найму: 65 %		

Рис. 2. Пример формы. Профессиограмма

Характеристика	Не выраженные	Определяемые	Выраженные
Чувствительность к внешним сигналам ?	+		
Принятие креативных решений ?			+
Устойчивость к внешнему давлению ?	+		
Общительность ?	+		
Системность в переговорах ?			+
Исполнительность ?	+		
Трудоспособность ?		+	
Коммуникабельность ?			+
Инициативность ?			+
Рациональность мышления ?			+
Целеустремленность ?	+		
Многозадачность ?	+		
Прогностические способности ?			+
Естественность поведения ?			+
Сводная характеристика			
• Изобретательность и находчивость в решении задач, поиске выхода из ситуации. • Последовательность, умение просчитать и осуществить ходы от А до Я. • Энергичность, природный запас физических сил, выносливость мышц и опорно-двигательного аппарата. • Умение налаживать контакт с людьми, понимать и воспринимать чужие мотивы, мысли, желания и уметь выразить свои. • Разумность, осмысленность в обдумывании вопросов. • Определенная способность предвидеть результаты своих и чужих поступков. • Свобода быть в том настроении, которое есть.			

Рис. 3. Пример формы. Экспресс диагностика личности

Заключение. Основные эффекты внедрения сервиса в центре занятости Пермского края:

- 1) сокращает время первичной диагностики кандидата с 2–3 часов до нескольких минут;
- 2) дает рекомендации по основным направлениям работы специалиста (профиль личностных компетенций, природные склонности личности);
- 3) автоматизирует процесс первичного подбора вакансии и обучающих курсов.

Для анализа точности работы сервиса проводилось сравнение результатов работы сервиса с традиционными тестами СМИЛ, а также собиралась обратная связь от тестируемых людей.

Точность заключений:

- по результатам сбора обратной связи испытуемых – 87%;
- по сравнению с тестом СМИЛ – 79%.

Достигнутая точность является достаточной для проведения первичного профориентационного тестирования. Для проведения более детальных тестирований и повышения точности диагностики, планируется расширить количество исходных параметров диагностики (по сравнению с визуальной диагностикой, выполняемой экспертами) и одновременно использовать нескольких методик интерпретации (с весовыми коэффициентами).

Созданное решение, по нашему мнению, может стать инструментом интеллектуальной поддержки принятия решений в сфере управления персоналом.

Компании смогут использовать функционал решения для таких задач:

1. Проведение регулярной оценки персонала, определение компетенций сотрудников, формирование индивидуальных планов развития.
2. Оптимизация массового поиска персонала.
3. Выявление высокопотенциальных сотрудников.
4. Анализ совместимости сотрудников в команде.

Библиографический список

1. Гердер И. Г. Идеи к философии истории человечества. М.: Наука, 1977. 704 с.
2. Люшер М. Цветовой тест Люшера. М.: АСТ; Санкт-Петербург: Сова, 2005. 192 с.
3. Тараненко В. История лица. Мастерская физиогномического психоанализа: [16+]. Киев: Мультимедийное Издательство Стрельбицкого, 2013. 440 с.
4. Пономаренко В. В. Практическая характерология с элементами прогнозирования и управления поведением (методика «семь радикалов»). Ростов-на-Дону: Феникс, 2006. 252 с.
5. Могильнер М. Ното імрегі: История физической антропологии в России. (Конец XIX – начало XX вв.). М.: Новое литературное обозрение. 2008. 512 с.
6. Ямпольский М. Б. Неожиданное родство. Рождение одной кинотеории из духа физиогномики // Искусство кино. 1986. № 12.
7. Рядчикова Ю. В. Физиогномика и традиционный китайский портрет // Научная сессия МИФИ-2006. Т. 6. М.: Институт восточных культур и античности при РГГУ.
8. Свидетельство о государственной регистрации программы для ЭВМ № 2022661455. Адаптированная версия интеллектуальной системы профдиагностики «Профотбор будущего» на основе технологии биометрического профайлинга / З. И. Сичинава, Ф. М. Черепанов. Заявка № 2022611789. Дата поступления 12 февраля 2022 г. Зарегистрировано в Реестре программ для ЭВМ 22 июня 2022 г.

SERVICE FOR QUICK ASSESSMENT OF A PERSON'S PROFESSIONAL POTENTIAL

Sichinava Zurabi Irodievich

NV-Emotions LLC

94-23, Samarkandskaya Str., Perm, Russia, 614089

sichinava@realnewvision.ru

The article describes the “Profotbor of the Future” service based on computer vision and artificial intelligence technologies, designed to optimize the process of initial profiling of job seekers when looking for a job. The solution is based on an analytical system that simulates the thinking of a human resources expert based on biometric image analysis. The “Profotbor of the Future” service has been implemented and is being used in 30 employment centers in the Perm Region

Keywords: artificial intelligence, neural network technologies, personnel management, optimization of mass recruitment of personnel, profile of personal competencies, determination of indicators of skills and abilities, assessment of a person's professional potential

МЕТОДИЧЕСКАЯ СИСТЕМА ПОДГОТОВКИ БУДУЩИХ ПЕДАГОГОВ К ИСПОЛЬЗОВАНИЮ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И АНАЛИЗА ДАННЫХ В ПРОФЕССИОНАЛЬНОЙ ДЕЯТЕЛЬНОСТИ

Худякова Анна Владимировна

Пермский государственный гуманитарно-педагогический университет
614990, Россия, г. Пермь, ул. Сибирская, 24
ahudyakova@pspu.ru

В статье представлено описание методической системы подготовки будущих педагогов к использованию технологий искусственного интеллекта и анализа данных в профессиональной деятельности. Система включает в себя целевой, содержательный, процессуальный и диагностический компоненты. Развитие цифровой грамотности бакалавров и магистров педагогического образования на дисциплинах коммуникативно-цифрового и предметно-методического модулей обеспечит их готовность к организации и выполнению различных видов деятельности в цифровой среде.

Ключевые слова: цифровые технологии, цифровая грамотность, экономика данных, подготовка учителя, дидактика высшего образования, большие данные, системы искусственного интеллекта

Введение. Одной из целей национального проекта «Экономика данных», реализация которого началась в январе 2025 г., является подготовка кадров для цифровой экономики. Согласно Стратегии научно-технологического развития Российской Федерации, использование цифровых технологий должно стать основой для повышения конкурентоспособности страны и обеспечения устойчивого экономического роста. В рамках Стратегии акцентируется внимание на следующих ключевых аспектах: инновации и развитие, образование и подготовка кадров, инфраструктура, совместные инициативы, безопасность и этика.

Цифровая трансформация государственного и муниципального управления, экономики и социальной сферы в рамках национального проекта «Экономика данных» будет достигнута за счет развития отечественных цифровых платформ, программного обеспечения, перспективных разработок и искусственного интеллекта. В этом контексте очень важно, чтобы учителя обладали готовностью к профессиональной деятельности в цифровой образовательной среде, в том числе в условиях использования технологий искусственного интеллекта, обеспечивая равные возможности и высокое качество образования.

Постановка проблемы. Необходимость разработки методической системы подготовки будущих педагогов к использованию технологий искусственного интеллекта и анализа данных в профессиональной деятельности вызвана противоречием между возросшими требованиями к уровню подготовки учителя в области современных цифровых технологий, обозначенными в инициативах национального проекта «Экономика данных» («Кадры для цифровой трансформации»),

«Искусственный интеллект», «Цифровые платформы в отраслях социальной сферы»), и неразработанностью для такой подготовки содержания, технологий, методов, форм и средств обучения.

Для определения путей ликвидации содержательно-деятельностного разрыва целесообразно провести исследование, решающее актуальную проблему методологии и технологии педагогического образования, по разработке системы подготовки современного учителя в рамках национальной повестки развития высшего образования и стратегических установок научно-технологического развития страны.

Гипотеза исследования формулируется в предположении, что формирование цифровой грамотности в области искусственного интеллекта и анализа данных будущего учителя будет происходить, если будет реализована методическая система, включающая в себя целевой, содержательный, процессуальный и диагностический компоненты.

Материалы и методы. В качестве теоретико-методологической основы разработки методической системы подготовки современного учителя в университете педагогического профиля выбран технологический подход, основанный на использовании современных технологий и методов работы с обучающимися для реализации учебного процесса и достижения планируемых результатов. Такой подход позволяет: анализировать и систематизировать на научной основе имеющийся практический опыт и его использование; комплексно решать образовательные и социально-воспитательные проблемы; обеспечивать благоприятные условия для развития личности; выбирать наиболее эффективные и разрабатывать новые технологии и модели для решения возникающих социально-педагогических проблем.

Результаты. Целевой компонент методической системы связан с использованием цифровой образовательной среды вуза для формирования цифровой грамотности у будущих учителей.

Целевая модель цифровой образовательной среды (далее – ЦОС) в рамках полномочий Минпросвещения России содержит:

- данные участников ЦОС;
- платформу ЦОС, в том числе информационные системы и ресурсы платформы ЦОС;
- государственные и иные информационные системы и ресурсы, используемые в сфере образования и (или) необходимые для обеспечения работоспособности платформы ЦОС, информационных систем и ресурсов в сфере образования в единой информационной среде;
- цифровой образовательный контент [1].

Подготовка учителей должна проводиться в контексте решаемых задач, связанных с основными направлениями их профессиональной деятельности. В связи с этим необходимо организовать профессионально направленную цифровую образовательную среду, которая включает в себя содержательное наполнение, выбранное сообразно планируемым видам профессиональной деятельности.

Для формирования цифровой грамотности в области искусственного интеллекта и анализа данных разработано содержание лабораторных работ, проводимых в рамках дисциплины «Технологии цифрового образования» для бакалавров педагогического образования. Данная дисциплина состоит из 4 разделов, включающих в себя 7 лабораторных работ, рассчитанных на 4 часа каждая [3]. При проведении исследования две лабораторные работы по дисциплине «Технологии цифрового образования» были посвящены использованию искусственного интеллекта и анализа данных.

В лабораторной работе по изучению технологии искусственного интеллекта студенты работают с генеративными нейросетями, создают тексты и изображения в различных онлайн-сервисах на основе искусственного интеллекта, сравнивают их функциональность, удобство использования и качество результатов. Заданиями для генерации контента выступают: сценарий занятия, план мастер-класса, викторина к образовательному событию, задачи для решения на уроке, сценарий родительского собрания, визитки на различные конкурсы, изображения по теме образовательного события.

Лабораторная работа по анализу данных посвящена кластерному и семантическому анализу данных в программах Orange Data Mining и Yandex DataLens. В качестве датасетов студенты используют реестры открытых данных Министерства просвещения РФ.

Процессуальный компонент методической системы содержит организационные, педагогические и кадровые условия формирования цифровой грамотности у будущих учителей. Организационные условия включают в себя использование средств цифровой образовательной среды для формирования цифровой грамотности (средовой подход). Педагогические условия обеспечивают методическое и дидактическое сопровождение процесса формирования цифровой грамотности через деятельностные образовательные практики. Кадровые условия связаны с диагностикой профессиональных дефицитов обучающихся и выстраиванием индивидуальных образовательных маршрутов. На лабораторных занятиях это может быть реализовано с помощью разноуровневых заданий.

Диагностический компонент методической системы включает в себя тестовые задания для оценки цифровой грамотности в области искусственного интеллекта и анализа данных [2].

Заключение. Результаты исследования подчеркивают необходимость внедрения систематического и комплексного подхода к обучению технологиям искусственного интеллекта и анализа данных в педагогическом вузе. Это позволит повысить готовность студентов к профессиональной деятельности в условиях экономики данных и развить цифровую грамотность, необходимую для успешной работы и адаптации к быстро меняющимся требованиям рынка труда.

Финансирование. Исследование выполнено в рамках государственного задания с Министерством Просвещения РФ по теме «Формирование цифровых компетенций студентов педагогических направлений подготовки в области искусственного интеллекта и анализа данных» (код научной темы ОТГЕ-2025-0021)».

Библиографический список

1. Приказ Минпросвещения России от 02.12.2019 № 649 «Об утверждении Целевой модели цифровой образовательной среды»: зарег. в Минюсте России 24.12.2019 № 56962.
2. Свидетельство о государственной регистрации базы данных № 2024624727 Российская Федерация. Диагностический инструмент для оценки сквозных цифровых компетенций педагогических работников № 2024624423. Заявл. 14.10.2024. Оpubл. 30.10.2024 / А. В. Худякова, Г. Р. Водяненко, В. Д. Щипицын и др.; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Пермский государственный гуманитарно-педагогический университет». URL: <https://elibrary.ru/item.asp?id=76380554>
3. Худякова А. В. Разработка содержания дисциплины «Технологии цифрового образования» в рамках внедрения модели «Ядро высшего педагогического образования» // Вестник Пермского государственного гуманитарно-педагогического университета. Серия: Информационные компьютерные технологии в образовании. 2023. № 19. С. 103–110. DOI 10.24412/2222-7520-2023-1-103-110

A SYSTEM FOR TRAINING FUTURE TEACHERS IN THE USE OF ARTIFICIAL INTELLIGENCE AND DATA ANALYTICS TECHNOLOGIES IN THEIR WORK

Anna V. Hudyakova

Str. Sibirskaya, 24, Perm, Russia, 614990

ahudyakova@pspu.ru

The article describes system of training future teachers to use artificial intelligence technologies and data analysis in their professional activities. The system includes several components: targeted, substantive, procedural, and diagnostic. The development of digital literacy of students in the disciplines of communication-digital and subject-methodical modules will ensure their readiness to organize and perform various types of activities in a digital environment.

Keywords: digital technologies, digital literacy, data economics, teacher training, didactics of higher education, big data, artificial intelligence systems

Научное издание

**Искусственный интеллект в решении
актуальных социальных и экономических проблем XXI века**

Сборник статей по материалам Десятой всероссийской
научно-практической конференции с международным участием

(г. Пермь, 9–10 октября 2025 г.)

Издается в авторской редакции

Подписано в печать 00.10.2025. Формат 60×90/16
Усл. печ. л. 37,43. Тираж 00 экз. Заказ №

Издательский центр
Пермского государственного
национального исследовательского университета
614990, г. Пермь, ул. Букирева, 15