




ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА

Часть 1

Пермь 2024

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

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


ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА

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

Часть 1

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

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



Пермь 2024

УДК 004.8: 3
ББК32.813 + 6/8
И868

Искусственный интеллект в решении актуальных социальных
И868 и экономических проблем XXI века : сборник статей по материалам
Девятой всероссийской научно-практической конференции с между-
народным участием (г. Пермь, ПГНИУ, 17–18 октября 2024 г.) / под
редакцией Л. Н. Ясницкого, Т. В. Миролубовой, М. В. Радионовой,
Е. Г. Плотниковой ; Пермский государственный национальный ис-
следовательский университет. – Пермь, 2024. – Ч. 1. – 333 с.

ISBN 978-5-7944-4170-3
ISBN 978-5-7944-4171-0 (Ч. 1)

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

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

УДК 004.8: 3
ББК 32.813 + 6/8

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

Партнёры конференции:

Пермское отделение Научного совета при президиуме РАН
по методологии искусственного интеллекта

Российская ассоциация искусственного интеллекта

Пермский национальный исследовательский политехнический университет
Национальный исследовательский университет «Высшая школа экономики»

Пермский государственный гуманитарно-педагогический университет
Пермский государственный медицинский университет им. академика Е.А. Вагнера

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

ISBN 978-5-7944-4170-3
ISBN 978-5-7944-4171-0 (Ч. 1)

© ПГНИУ, 2024

ОГЛАВЛЕНИЕ

<i>Русаков С.В.</i> Юрий Владимирович Девингталь – учёный, организатор, хороший человек (100 лет со дня рождения).....	8
Искусственный интеллект и философия, футурология, этика, правовые основы.....	10
<i>Ясницкий Л.Н.</i> Будущее искусственного интеллекта: прогноз пермских ученых.....	10
<i>Габриелян О.А., Сулейменов И.Э.</i> Искусственный интеллект как посредник между человеком и надличностным уровнем переработки информации.....	17
<i>Непомнящий А.В.</i> Философия искусственного интеллекта: от мифа к интегральному видению.....	21
<i>Гибадуллин В.С., Дмитриев В.Г., Галиева А.И., Галиева Г. И.</i> Философское осмысление: интеллект человека и машины.....	27
<i>Фиговский О.Л.</i> Искусственный интеллект: военное применение.....	30
<i>Зотина Г.В., Патакина А.С.</i> Вопросы этики и ответственности при разработке и внедрении искусственного интеллекта.....	33
<i>Тобиен М.А.</i> Использование технологий искусственного интеллекта в научной и инновационной деятельности.....	38
<i>Титов В.Д.</i> Искусственный интеллект и разрывы ответственности: вызовы, риски и этические дилеммы автономных систем.....	42
<i>Романова А.С.</i> Алгоритмическое право как основа для внедрения автономных систем для управления корпорациями.....	47
<i>Песецкая Т.И.</i> Модель интеллектуального управления системой ценностных частных актора социокультурного пространства.....	51
<i>Сметана В.В.</i> Появление постлюдей и киборгов: стирание границ между людьми и машинами.....	58
<i>Козлов М.В.</i> Отличительный признак интеллекта. Когнитивное и стереотипное мышление. Креативный гомеостаз робастной квадриархии.....	67

Искусственный интеллект и безопасность.....	73
<i>Тринчин В.В.</i>	
Искусственный интеллект как объект кибератак: уязвимости систем, риски.....	73
<i>Лецинский Б.С., Васильев Н.А., Хабушев Р.Р., Назаров А.Р.</i>	
Вопросы применения искусственного интеллекта в безопасности.....	77
<i>Бекетнова Ю.М.</i>	
Методы машинного обучения в решении задач экономической безопасности и финансового мониторинг.....	82
<i>Зиманова М.А.</i>	
Использование таможенными органами технологий искусственного интеллекта для упрощения процедур торговли и обеспечения безопасности трансграничной торговли.....	87
<i>Рабчевский А.Н., Ашихмин Е.Г.</i>	
Об опыте использования больших языковых моделей в сфере информационного противоборства.....	92
<i>Фадеева И.П., Смолькин В.П.</i>	
Использование систем искусственного интеллекта в области социальной инженерии.....	100
<i>Хорошавина О.Н.</i>	
Влияние искусственного интеллекта на процессы формирования информационных пузырей в социальных медиа.....	104
Искусственный интеллект и экономика.....	109
<i>Багаутдинова Н.Г., Исмаилов И.И., Алсаид Г.</i>	
Регрессионное моделирование на основе нечетко-множественного подхода с приложениями к анализу экономического роста.....	109
<i>Коротченко Д.С., Шмидт С.А.</i>	
Разработка инновационного подхода к исследованию уровня потребительской лояльности в сфере авиаперевозок с применением методов машинного обучения.....	114
<i>Лашкевич Е.В.</i>	
Влияние финансовых показателей на устойчивость компаний в разных странах.....	119
<i>Зянкина Е.Г.</i>	
Нейросетевая система прогнозирования стоимости жилой недвижимости первичного рынка в городе Перми.....	125
<i>Горбач М.П.</i>	
Тензорные бандиты и их приложения.....	131
<i>Лаврентьева О.Н.</i>	
Применение модели chatgpt в финансовой сфере и сравнение ее рекомендаций с рекомендациями робоэдвайзинговых сервисов.....	136

<i>Зеленко М.А., Солушко А.С.</i>	
Персонализация потребительского опыта с помощью искусственного интеллекта.....	141
<i>Гончаров С.А.</i>	
Нейросетевая система прогнозирования зарплаты python-разработчика.....	145
<i>Гарафутдинов Р.В.</i>	
Применение LSTM-нейронной сети и фрактального анализа для прогнозирования фондового индекса.....	149
<i>Васильев В.Д.</i>	
Нейросетевая система прогнозирования развития инфраструктуры кампуса НИУ ВШЭ – Пермь.....	154
<i>Колесник Н.А.</i>	
Искусственный интеллект для формирования экономики замкнутого цикла.....	159
<i>Куца А.А.</i>	
AI-аналитика и оптимизация клиентского опыта: от прогнозирования поведения до автоматизации обслуживания.....	163
<i>Ощепков В.А.</i>	
Влияние LLM моделей на рынок труда.....	167
<i>Патласов Д.А.</i>	
Функция потерь QUANTILE LOG COSH в рекуррентных нейронных сетях и восстановленная волатильность: инновационные методы прогнозирования волатильности.....	171
<i>Савин В.С., Мурзин А.Д.</i>	
Влияние искусственного интеллекта на трансформацию бизнес-моделей.....	175
<i>Варнухов А.Ю.</i>	
Применение методов машинного обучения для определения факторов, влияющих на объем продаж товаров на маркетплейсе.....	181
<i>Иванов А.И., Тарасов Д.В.</i>	
Нейросетевой анализ нелинейной динамической модели рынка с гистерезисом на основе алгоритма оценки показателя Хёрста на малых выборках.....	186
<i>Шафар И.В.</i>	
Алгоритмы для трейдинга.....	192
<i>Шориков А.Ф.</i>	
Оптимизация программного управления прогнозированием состояния фазового вектора нелинейной дискретной управляемой динамической системы.....	197
Искусственный интеллект, техника и промышленные технологии.....	204
<i>Миролюбова Т.В., Рыбакин В.И., Голдобин М.А., Морозов А.А., Мезенцев А.С., Ясницкий В.Л., Ясницкий Л.Н.</i>	
Опыт создания и внедрения интеллектуальных систем на промышленных предприятиях.....	204

<i>Светлов В.Н.</i>	
Нейросетевая система прогнозирования и выявления причин брака при прессовании литейных стержней.....	208
<i>Штейнле Д.К., Ясницкий Л.Н.</i>	
Анализ данных и создание системы машинного обучения для оптимизации процесса выплавки высокопрочной стали.....	214
<i>Кулик С.Д., Ахметов А.Ф., Зинченко А.П.</i>	
Разработка программного средства для распознавания заданных объектов	221
<i>Аль Уатик Х.С., Пронин С.П.</i>	
Роль искусственного интеллекта в предиктивном обслуживании промышленного производства: исследование на примере редукторов ветроустановок.....	225
<i>Ясницкий В.Л., Мезенцев А.С.</i>	
Построение рекомендательных систем на базе машинного обучения в условиях серийного производства.....	229
<i>Шереметьева А.С., Полушин А.А., Сухно И.В., Смышляев Н.А., Абраменко В.А.</i>	
Нейросетевой классификатор для обнаружения фальсифицированных кормов.....	233
<i>Медведев И.А., Корнаухова М.А.</i>	
Комбинация нейронной сети и математической модели прогнозирования напряжения микробных топливных элементов.....	238
<i>Бахтин П.В., Проскуряков В.С.</i>	
Нейросетевая система определения легированного слоя сердцевины преформы-стержня на линии mcvd для вытягивания оптоволокна.....	242
<i>Азанов А.А., Хейфец И.И., Ясницкий Л.Н.</i>	
Оптимизация технологического процесса производства кабельной продукции.....	248
<i>Ташкинов А.Г.</i>	
Методологический подход к формированию цифрового представления промышленных предприятий в городе Перми.....	251
Искусственный интеллект, медицина и здравоохранение.....	257
<i>Назаров Д.М., Бадаев Ф.И.</i>	
Сущность применения LLM моделей в сфере здравоохранения.....	257
<i>Петрунина Е.В., Пшеничный А.Е., Ермаков Д.А.</i>	
Метод формирования дескрипторов для классификаторов мышечной усталости, основанный на вейвлет-анализе сегментов электромиосигнала.....	262
<i>Лукин М.К.</i>	
Нейросетевая система диагностики сахарного диабета.....	269
<i>Грибков Д.Н., Горбаченко В.И., Потапов В.В., Милтых И.С., Зенин О.К.</i>	
Нейросетевая классификация результатов диагностики хронической сердечной недостаточности методом тензиометрии.....	276

<i>Андреев И.В.</i>	
Нейросетевая система прогнозирования инсульта.....	284
<i>Бреничев Н.А.</i>	
Разработка веб-приложения для определения диагноза у пациентов с заболеванием легких.....	291
<i>Черемухин А.Д.</i>	
О тенденциях современных исследований в области методов отбора признаков.....	294
<i>Сидорова Т.И.</i>	
Нейросетевая система прогнозирования вероятности диабета.....	301
<i>Митюшкина А.В.</i>	
Нейросетевая система прогнозирования сердечного приступа.....	306
<i>Ясницкий Л.Н., Думлер А.А.</i>	
Почему современные медико-диагностические системы искусственного интеллекта работают так плохо.....	313
<i>Жвакин А.А., Арутюнян В.Б., Породилов А.А., Наумова Н.А., Южакова К.В., Абубакирова О.А., Степанов М.С.</i>	
Искусственный интеллект в диагностике сердечно-сосудистых заболеваний на основе минимального набора данных.....	318
<i>Попов И.Е., Крылова А.Е., Скобей И.В.</i>	
Интеллектуальный анализ термометрических данных головного мозга пациентов с нарушенным сознанием.....	323
<i>Думлер А.А., Утева Н.А., Ясницкий Л.Н.</i>	
Интеллектуальная система «Kardionet» в диагностике острого коронарного синдрома в условиях выездной бригады скорой медицинской помощи: «полевые испытания».....	328

**ЮРИЙ ВЛАДИМИРОВИЧ ДЕВИНГТАЛЬ –
УЧЁНЫЙ, ОРГАНИЗАТОР, ХОРОШИЙ ЧЕЛОВЕК
(100 лет со дня рождения)**



Юрий Владимирович Девингталь (30.09.1924 – 17.11.1997) – создатель вычислительного центра ПГУ (1960 г.) и его бессменный научный руководитель на протяжении 30 лет. По его инициативе в университете появилась специальность прикладная математика (1971 г.) и профильная кафедра прикладной математики (1972 г.), которой он руководил на протяжении 12 лет. Всё это позволило создать, совершенствовать и развивать массовую подготовку кадров ИТ-отрасли в Пермской области. Без всякого сомнения, этот период (1960–1990), когда чрез вычислительный центр прошли три поколения ЭВМ и многие десятки молодых специалистов, можно называть эрой Ю.В. Девингталя. О масштабах этой деятельности можно судить хотя бы по тому

факту, что в конце 80-х годов в ВЦ работало около 130 сотрудников: программистов, электронщиков, сотрудников научных лабораторий, вспомогательного персонала. Товарищескую, дружескую атмосферу этого большого коллектива, отношение его работников к своему руководителю подчеркивает тот факт, что за глаза все его называли просто ЮВ. За эти тридцать лет на кафедре прикладной математики были подготовлены сотни специалистов ИТ-сферы, в качестве сотрудников ВЦ начинали свою научную деятельность десятки кандидатов и докторов наук, среди которых можно отметить таких знаковых для университета профессоров, как Е.Л.Тарунин и И.С.Утробин, работавших ещё в немногочисленном первом составе сотрудников ВЦ ПГУ.

Моё личное знакомство с Юрием Владимировичем состоялось в 1972 году, когда я поступил в университет на специальность прикладная математика. На третьем курсе он читал нам дисциплину «Численные методы» настолько яр-

ко и увлекательно, что это во многом определило сферу моей научной деятельности в области вычислительной математики. Именно он настоял на том, чтобы я поехал на преддипломную практику в МГУ, за которой последовала целевая аспирантура на кафедре академика А.Н. Тихонова. Таким образом, его роль организатора-руководителя в моём становлении как учёного трудно переоценить. А много позже «Численные методы» у прикладников довелось мне подхватить после ухода Юрия Владимировича и читать эту дисциплину более четверти века.

В годы нашей учёбы именно Юрий Владимирович познакомил нас студентов с задачами распознавания образов, аналитическими вычислениями на ЭВМ, рассказал о персептроне. Уже в середине 70-х годов мы работали на машине «МИР-3», позволявшей аналитически получать производные и первообразные для некоторого класса функций и решать аналитически ещё целый ряд задач. В те далекие годы повседневное, как сегодня, обсуждение роли искусственного интеллекта в разных сферах нашей жизни трудно было себе представить. Правда в среде математиков и философов активно велась дискуссия на тему «Может ли машина мыслить», ярким ответом на которую, явился плакат, висевший в ту пору терминальном классе СМ ЭВМ: «Машина не должна мыслить, машина должна ездить!»

Разница в датах дней рождения Юрия Владимировича и моего всего несколько дней, а в годах 30 лет. Однажды во время очередного «нашего» юбилея он мне сказал: «Сегодня я вдвое старше Вас, но эта относительная разница будет с каждым годом убывать». Действительно, на текущий момент это уже примерно 1.43 раза.

С.В. Русаков, д.ф.-м.н., профессор, заведующий кафедрой прикладной математики и информатики ПГНИУ в период 1999-2024 гг.

Секция: Искусственный интеллект и философия, футурология, этика, правовые основы

УДК 004.032.26

БУДУЩЕЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: ПРОГНОЗ ПЕРМСКИХ УЧЕНЫХ

Ясницкий Леонид Нахимович

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

В статье приведено мнение автора о будущем искусственного интеллекта, основанное на его многолетнем опыте научной работы в этой области. Обращается внимание на то, что, увлекшись применением методов искусственного интеллекта для удовлетворения текущих потребностей общества, ученые мало обращают внимание на его главную возможность. Это способность нейронных сетей открывать новые, неизвестные ранее законы природы, общества, вселенной, мироздания. По мнению автора, будущее искусственного интеллекта связано именно с этой его способностью.

Ключевые слова: прогнозы будущего, открытие законов природы, искусственный интеллект, нейронные сети.

Прогнозы будущего всегда были и остаются актуальны.

В области прогнозирования будущего искусственного интеллекта наиболее известными, по-видимому, являются 10 предсказаний, сделанных в 1957 году нобелевским лауреатом Гербертом Саймоном [1]:

- *В ближайшее десятилетие ЭВМ завоюет титул чемпиона мира по шахматам.*
- *В пределах десяти лет ЭВМ откроет и сумеет доказать новую важную математическую теорему.*
- *В десятилетний срок большинство теорий в области психологии примет вид программ для вычислительной машины.*
- *И т.д.*

Известны, сделанные в 2005 году прогнозы американского изобретателя и футуролога Рэя Курцвейла. Вот некоторые из них.

- *Естественный процесс мышления не будет иметь преимущества по сравнению с машинным. Системы искусственного интеллекта получат равные права с человеком. Разница между человеком и машиной исчезнет.*
- *Системы искусственного интеллекта превзойдут по численности естественных людей.*

– Несмотря на недостатки естественных людей, системы искусственного интеллекта уважают их как своих прародителей.




Рис. 1. Варианты прогнозов будущего искусственного интеллекта.

Мы воздержимся от обсуждения приведенных выше прогнозов, а вместо этого изложим собственное видение будущих успехов систем искусственного интеллекта, основываясь на результатах пермских ученых, которыми мы реально располагаем уже сейчас.

1. Реально создание интеллектуальных медико-диагностических систем, превосходящих по точности постановки диагнозов естественных врачей. Реально выявление с помощью интеллектуальных систем новых неизвестных ранее медицинских знаний и использование этих знаний для улучшения качества медицинской практики.

сердца. Помимо диагностики и прогнозирования развития заболевания на много лет вперед, наша система дает рекомендации по профилактики заболеваний. За последние 10 лет эксплуатации система не сделала ни одной ошибки.

2. Реально создание интеллектуальных систем диагностики сложных технических устройств, превосходящих по своим возможностям и точности известные инженерные методики. Их внедрение в инженерную практику позволит повысить надежность технических устройств и, таким образом, способствовать решению проблемы снижения техногенных аварий и катастроф – одной из актуальных проблем XXI в.

Наш опыт разработки нейросетевых систем диагностики авиационных двигателей показал [4, с.83–87], что интеллектуальные системы позволяют выявлять такие дефекты, которые обычными инженерными методами выявлены быть не могут.

3. Реально создание интеллектуальных систем, способных получать точные, не имеющие математической погрешности, аналитические решения краевых задач математической физики. Внедрение таких интеллектуальных систем в инженерную практику, также будет способствовать снижению числа техногенных аварий и катастроф.

В [4, с.183–188] Изложен наш опыт создания и применения для решения инженерных задач экспертной системы, которая, используя математические знания математиков прошлых веков, получает точные аналитические решения краевых задач теории упругости, теории теплопроводности, теории электрических и магнитных полей. Обратиться к интеллектуальной системе можно с нашего сайта www.PermAI.ru.

4. Реально создание интеллектуальных систем, прогнозирующих экономическое состояние предприятий и позволяющих разрабатывать рекомендации по оптимизации их деятельности.

В нашей работе [5] описан опыт создания нейросетевой системы прогнозирования вероятности банкротства российских банков. Помимо прогнозов, система позволяет получать полезные рекомендации по предотвращению банкротства конкретных банков. Программа выложена на нашем сайте www.PermAI.ru.

5. Реально создание интеллектуальных систем, предназначенных для прогнозирования развития политических событий и влияния на эти события.

В книге [4, с. 91–95] описан случай подтвердившегося впоследствии прогнозирования победы Д.А. Медведева на президентских выборах 2008 г., опубликованных в [6, с. 79–85] за полтора года до этих выборов. В [7] приведены подтвердившиеся результаты прогнозирования рейтингов известных политических деятелей, а также рекомендации по улучшению этих рейтингов.

В нашей работе [8] изложен опыт создания нейросетевой системы, прогнозирующей вероятность возникновения беспорядков в разных странах: восстаний, государственных переворотов, революций. Помимо прогнозирования наступления этих событий система позволяет разрабатывать рекомендации по их предотвращению.

6. Реально создание и применение интеллектуальных систем в области криминалистики.

В нашей работе [9] описан опыт создания нейросетевого детектора лжи, значительно превосходящего известные штатные аналоги по точности заключений.

В работе [10] изложен опыт создания интеллектуальной системы, предназначенной для изучения личности и выявления серийных убийц. Программа, оценивающая склонность человека к насилию, выложена на нашем сайте www.PermAI.ru.

7. Реально создание интеллектуальных систем, предназначенных для прогнозирования результатов спортивных состязаний и для оптимизации программы подготовки спортсменов с целью получения наивысших спортивных результатов.

В нашей практике нейронные сети уже применялись для прогнозирования результатов Олимпийских игр 2014 г. [11], чемпионата мира 2015 г. [12], а также при разработке рекомендаций для известных спортсменов [13] и футбольных команд [14].

8. Реально создание и широкое применение интеллектуальных систем в психологии.

Напомним третье предсказание нобелевского лауреата Герберта Саймона, приведенное в начале этой статьи:

– В десятилетний срок большинство теорий в области психологии примет вид программ для вычислительной машины.

Мы знаем, что два первых предсказания, хотя и с опозданием, но сбылись. Однако о третьем предсказании Саймона мы ничего подобного пока сказать не можем. Почему?

Пытаясь решать задачи психодиагностики, психологи выдвигают различные гипотезы, называют в качестве наиболее важных те или иные факторы, влияющие, по их мнению, на способности и предрасположенности человека. Они вводят такие труднодоступные для количественной оценки понятия, как «сила воли», «сила характера» и др., разрабатывают различные тесты для их измерения. Естественно, что при сборе статистической информации возникают проблемы, особенно если речь идет о человеке, жившем в прошлых веках. В то же время, психологи обычно не обращали внимания на легкодоступную информацию о людях, известную, например, из астрологических и нумерологических баз, отвергая ее как лженаучную.

По-нашему мнению, психологи еще не полностью освоили и оценили возможности современных методов интеллектуального анализа данных, которые позволяют на начальных стадиях создания интеллектуальных систем в качестве входных параметров вводить любое количество любых факторов. В ходе исследований таких математические модели всегда можно выяснить, какие из этих факторов действительно влияют на результат моделирования, а какие — нет, вне зависимости от того, признаются эти факторы официальной наукой, или нет.

Заметим, что наш небольшой опыт применения нейросетевых технологий для создания интеллектуальных систем, выявляющих способности и предрасположенности человека, оказался весьма успешным. Так, в работе [15] описана интеллектуальная система, выявляющая способность человека к руководящей деятельности, в [16] и [4, с. 101–105] – к научной деятельности, в [17] – к бизнесу. В [18] описана интеллектуальная система, способная прогнозировать степень успешности будущей карьеры студентов вуза, что позволяет оптимальным способом подбирать траектории их обучения. В [19] приведен опыт создания системы, определяющей предрасположенность подростков к наркотической зависимости, а также позволяющей получать индивидуальные рекомендации по снижению такой зависимости. В [10] – предрасположенность человека к насилию. Имеются программы, оценивающие предрасположенность человека к суициду, анорексии и др. Эти программы находятся в свободном доступе в разделе «Проекты» нашего сайта www.PermAI.ru. Помимо количественной оценки способностей, склонностей и предрасположенностей людей, с помощью этих программ можно получать полезные рекомендации по их развитию или, наоборот, снижению.

Таким образом, у нас есть все основания надеяться, что упомянутое выше третье предсказание Герберта Саймона о широком применении компьютерных программ в психологии в скором времени сбудется, причем, не только в пределах нашей научной школы.

9. Реально применение методов искусственного интеллекта в областях, выходящих за рамки традиционных наук. Реально получение новых, ранее неизвестных, но полезных для практического применения знаний, в том числе таких, которые меняют наше представление о мире. Можно надеяться, что методы искусственного интеллекта помогут наконец разгадать загадки эзотерики, уфологии, астрологии и других переживших века учений, выходящих за рамки современного миропонимания.

Как уже отмечалось, на нашем сайте www.PermAI.ru выложены интеллектуальные системы, позволяющие ставить диагнозы медицинских заболеваний, выявлять способности людей к бизнесу, к научной деятельности, к руководящей деятельности, склонности к наркомании, суициду, анорексии, насилию и другим порокам. Во многих случаях низкая погрешность результатов, зафиксированная при тестовых испытаниях программ, обеспечивается еще и тем, что, помимо традиционных входных параметров, учитываются параметры, влияние которых неочевидно. Природу влияния таких параметров пока не удастся объяснить в рамках современного уровня развития науки. Но это не мешает их использовать при создании эффективных и весьма полезных для практики интеллектуальных систем.

10. Реально применять методы искусственного интеллекта для открытия новых законов природы, общества, вселенной, мироздания.

Авторы этой статьи при проведении практических занятий обычно дают задание студентам: открыть заново теорему Пифагора, открыть заново закон Архимеда, открыть все законы Ньютона и т.д. И студенты, так же, как и ученые древности, вырезают прямоугольные треугольники, измеряют их стороны, а за-

тем обучают на этой информации нейронную сеть, которая заново повторяет подвиг древних геометров. Но раз так, значит нейронные сети, в принципе, могут открывать не только известные, но и неизвестные людям законы, причем не только законы природы, но и законы общества, вселенной, мироздания [20].

По-нашему мнению, искусственный интеллект, став самой популярной научной дисциплиной и заняв лидирующее положение в научных разработках, еще далеко не реализовал своих возможностей. Следуя современным потребностям, разработчики упускают самую главную возможность искусственного интеллекта – его способность открывать новые, неизвестные ранее законы. Познание с помощью искусственного интеллекта новых законов природы, общества, вселенной, мироздания, самого себя – это и есть тот главный путь, по которому должно идти человечество.

Библиографический список

1. Эндрю А. Искусственный интеллект. М.: Мир, 1985. 265 с.
2. Ясницкий Л.Н. Поучительное прошлое, блестящее настоящее и сомнительное будущее искусственного интеллекта (Пленарный доклад) // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Третьей всерос. науч.-практ. конф. (г. Пермь, 14–18 мая 2018 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2018. – С. 9 – 13. <https://cloud.mail.ru/public/CSfY/ZL2XzLCqL>
3. Yasnitsky L.N., Dumler A.A., Cherepanov F.M., Yasnitsky V.L., 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. November, 2021 DOI: 10.1080/23808993.2021.1993595
4. Ясницкий Л.Н. Интеллектуальные системы : учебник. М.: Лаборатория знаний, 2016. 221 с. <https://cloud.mail.ru/public/5H3z/4LxCpisxw>
5. Ясницкий Л. Н., Иванов Д. В., Липатова Е. В. Нейросетевая система оценки вероятности банкротства банков // Бизнес-информатика. 2014. № 3. С. 49–56.
6. Ясницкий Л. Н. Интеллектуальные информационные технологии и системы. – Пермь: Пермский государственный университет, 2007. 271 с.
7. Ясницкий Л. Н. О возможностях применения методов искусственного интеллекта в политологии // Вестник Пермского университета. Серия: Политология. 2008. № 2. С. 147–155
8. Пермяков А.М., Ясницкий Л.Н. Оценка возможности сохранения порядка в государстве с применением искусственных нейронных сетей // Прикладная математика и вопросы управления. – 2021. – № 1. – С. 95–118. – DOI: 10.15593/2499-9873/2021.1.06
9. Петров А.М., Ясницкий Л.Н. Возможности создания нейросетевого полиграфа // Вестник Пермского университета. Математика. Информатика. Механика. – Вып.2. – Пермь: Изд. Пермского ун-та, 2005. – С.43-47.
10. Ясницкий Л. Н., Ваулева С. В., Сафонова Д. Н., Черепанов Ф. М. Использование методов искусственного интеллекта в изучении личности серийных убийц // Криминологический журнал Байкальского государственного университета экономики и права. 2015. Т. 9, № 3. С. 423–430
11. Ясницкий Л. Н., Павлов И. В., Черепанов Ф. М. Прогнозирование результатов Олимпийских игр 2014 года в неофициальном командном зачете методами искусственного интеллекта // Современные проблемы науки и образования. 2013. № 6; URL: <http://www.science-education.ru/113-11206>
12. Ясницкий Л. Н., Кировоса А. В., Ратегова А. В., Черепанов Ф. М. Прогноз результатов чемпионата мира-2015 по легкой атлетике методами искусственного интеллекта // Современные проблемы науки и образования. 2014. № 4; URL: www.science-education.ru/118-14423
13. Ясницкий Л. Н., Внукова О. В., Черепанов Ф. М. Прогноз результатов Олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта // Современные проблемы науки и образования. – 2014. № 1; URL: <http://www.science-education.ru/115-11339>
14. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по

футболу Евро-2016 методом нейросетевого моделирования // Вестник спортивной науки. 2015. № 5. С. 15-20. https://www.elibrary.ru/download/elibrary_26644435_20792367.pdf

15. Ясницкий Л. Н., Михалева Ю. А., Черепанов Ф. М. Возможности методов искусственного интеллекта для выявления и использования новых знаний на примере задачи управления персоналом // International Journal of Unconventional Science. Журнал Формирующихся Направлений Науки. 2014. Вып. 6; URL: <http://www.unconv-science.org/n6/yasnitsky>

16. Байдин Д. Ю., Макурина Т. В., Черепанов Ф. М., Ясницкий Л. Н. Нейросетевая система прогнозирования склонности к научной деятельности // Актуальные проблемы математики, механики, информатики: сб. тез. Научно-практ. Конф. (Пермь, 30 октября – 1 ноября 2012 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2012. С. 153.

17. Ясницкий Л. Н., Порошина А. М., Тавафиев А. Ф. Нейросетевые технологии как инструмент для прогнозирования успешности предпринимательской деятельности // Российское предпринимательство. 2010. № 4(2). С. 8–13.

18. Ясницкий Л. Н., Кузнецов А. Г., Селезнева С. М., Солохина А. Д., Тюлькина Д. В., Черепанов Ф. М. Применение нейросетевых технологий в изучении акмеологического потенциала студентов вуза // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 4. С. 120–126.

19. Ясницкий Л. Н., Грацилев В. И., Куляшова Ю. С., Черепанов Ф. М. Возможности моделирования предрасположенности к наркозависимости методами искусственного интеллекта. Вестник Пермского университета. Серия: Философия. Психология. Социология. 2015. № 1(21). С. 61–71.

20. Ясницкий Л. Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56. <https://cloud.mail.ru/public/2Dtu/5BYLQvb8L>

THE FUTURE OF ARTIFICIAL INTELLIGENCE. FORECAST OF PERM SCIENTISTS

Leonid N. Yasnitsky

Perm State National Research University
Bukireva str., 15, Perm, Russia, 614068
HSE University,
Str. Studencheskaya, 38, Perm, Russia, 614070
yasn@psu.ru

The article presents the author's opinion on the future of artificial intelligence, based on his many years of scientific experience in this field. It is noted that, carried away by the use of artificial intelligence methods to meet the current needs of society, scientists pay little attention to its main opportunity. This is the ability of neural networks to discover new, previously unknown laws of nature, society, the universe, and the universe. According to the author, the future of artificial intelligence is connected precisely with this ability.

Keywords: future forecasts, discovery of the laws of nature, artificial intelligence, neural networks.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ КАК ПОСРЕДНИК МЕЖДУ ЧЕЛОВЕКОМ И НАДЛИЧНОСТНЫМ УРОВНЕМ ПЕРЕРАБОТКИ ИНФОРМАЦИИ

Габриелян Олег Аршавирович

Крымский федеральный университет имени В.И. Вернадского,
295007, Россия, г. Симферополь, ул. Ялтинская, 20
gabroleg@mail.ru

Сулейменов Ибрагим Эсенович

Казахский национальный университет имени аль-Фараби
050040, Казахстан, г. Алматы, ул. аль-Фараби, 71
esenych@yandex.ru

Рассматривается информационно-коммуникативная среда как новая форма существования материи, обладающая дуальной природой. Именно в этой среде формируются надличностные структуры как результат коммуникации людей. Это взаимодействие описывается нейросетевой моделью. Определяются такие феномены как профессиональное сознательное и профессиональное бессознательное. Выдвигается и обосновывается гипотеза о том, что Искусственный Интеллект открывает возможность взаимодействия человеческого сознания с ними, как с надличностными структурами.

Ключевые слова: искусственный интеллект, надличностные структуры, профессиональное коллективное сознательное, профессиональное коллективное бессознательное.

В настоящее время уже не вызывает сомнений, что сознание человека имеет дуальную природу: в нем одновременно присутствуют и индивидуальная, и коллективная составляющие. Доказательства этому на основе нейросетевой теории ноосферы даны в работах [1-3], причем уже имеются и независимые экспериментальные подтверждения [4] данной концепции. Из вывода о дуальной природе сознания человека вытекает вывод о существовании надличностного уровня переработки информации [2,3]. Этот вывод заставляет кардинально пересмотреть существующие воззрения на социально-экономическую роль искусственного интеллекта (ИИ).

В текущей литературе представлены, как правило, две противоположные точки зрения на роль ИИ в дальнейшем развитии цивилизации. Одна из них условно может быть названа апологетической. Ее сторонники настаивают на том, что ИИ может взять на себя выполнение рутинных операций, шире – сделать то, что в период Первой промышленной революции сделало внедрение машин в широкое использование, т.е. повысить производительность труда, в том числе интеллектуального. Тезисами такого рода широко пользуются представители противоположной (условно – алармистской – точки зрения), утверждающие, что ИИ может вначале сделать ненужными целый ряд профессий, а после – кардинально трансформировать сущность сознания человека, причем настолько, что допустимо говорить о дегуманизации.

На наш взгляд, ни та, ни другая точка зрения в полной мере не отражают возможности ИИ в части его влияния на общество. Аргументировать это можно на основе анализа взаимодействия человека с надличностным уровнем переработки информации.

Механизм формирования данного уровня можно пояснить следующим образом. Такие информационные объекты как интеллект и сознание человека порождаются обменом сигналами между нейронами головного мозга. Однако, любое общение между индивидами физически также сводится к обмену (опосредованному языком и речью) сигналами между нейронами, но только принадлежащими к различным индивидам [2, 3]. Следовательно, коммуникации между индивидами приводят к формированию глобальной нейронной сети – ноосферы. Более того, данный вывод позволяет говорить о существовании инфокоммуникационной среды как объективной реальности [5].

Существование надличностного уровня переработки информации определяет, в том числе, и дуальную сущность интеллекта и сознания человека. Нейронная сеть, порожденная головным мозгом индивида, физически является только относительно самостоятельным фрагментом объемлющей нейронной сети – ноосферы.

Как показано в [3], есть все основания полагать, что взаимодействие между личностным и надличностным уровнями переработки информации было весьма выраженным в период до становления индивидуального сознания, но сохраняется и сейчас. Подчеркнем еще раз, что в литературе уже описаны эксперименты, непосредственно подтверждающие существование надличностного уровня переработки информации [4].

Проявлениями такого взаимодействия являются творческие озарения, существование интуиции и т.д. [6]. Это позволяет утверждать, что существование надличностного уровня переработки информации представляет вполне определенный ресурс, которым можно и нужно научиться пользоваться, как минимум, для повышения эффективности (а точнее – кардинальной модернизации) высшего образования [7]. Как подчеркивалось в цитированной работе [7], возрастающий объем информации, который должен усвоить молодой ученый для того, чтобы стать профессионалом своего дела, постепенно приближается к критическому уровню [8]. Существует предел, который может усвоить мозг индивида. Далее необходимо изыскивать иные средства, что и заставляет обратить самое пристальное внимание на ресурсы надличностного уровня переработки информации, в частности на ресурсы профессионального коллективного сознательного и коллективного бессознательного [9]. К коллективному сознательному мы относим, тот объем знаний, который доступен рациональному освоению. Например, научные теории. К профессиональному коллективному бессознательному мы относим, на порядок более сложную надличностную структуру, в которой формируются неявные для человеческого интеллекта связи и отношения.

Механизм формирования профессионального коллективного сознательного и коллективного бессознательного можно раскрыть следующим образом. Коллективное бессознательное заведомо формируется на надличностном уровне переработки информации, в противном случае оно не было бы коллективным. Можно отметить, что нейросетевая теория ноосферы [5] позволяет по-

следовательно раскрыть сущность коллективного бессознательного. Примем во внимание, что надличностный уровень переработки информации формируется в межличностных коммуникациях. Эти коммуникации сложным образом структурированы (что отвечает марксистской трактовке человека как совокупности общественных отношений). Соответственно, структурированным является и коллективное бессознательное, его частью является профессиональное коллективное бессознательное.

Это возвращает нас к социально-экономической роли ИИ. Как отмечалось в работе [10], существует вполне определенная иерархия информационных объектов, одну из высших ступеней в которой занимает интеллект человека. Его существование неотделимо от существования человеческого сознания, механизмы формирования которого остаются пока неизвестными. Соответственно, вопрос о том, какие конкретно программные продукты можно относить к ИИ, а какие – нет, является беспредметным, широко толкуемым. Коль скоро неизвестно, что представляет собой интеллект как таковой, бессмысленно пытаться создать классификацию систем, претендующих на то, чтобы называться ИИ, тем более в смысле сильного ИИ. Это утверждение не исключает конвенциональные допущения по этому вопросу.

Этот вывод, однако, носит общеметодологический характер. Общественное сознание уже усвоило термин ИИ безотносительно к возможности последовательного обоснования данного понятия. Его восприятие носит преимущественно интуитивный характер, и именно в таком качестве его и оправдано анализировать с точки зрения потенциального влияния на общество.

Каким бы «слабым» не был ИИ, он уже способен выполнять вполне определенную социальную функцию – обеспечить максимально плотное взаимодействие индивида с информационно-коммуникационной средой, что уже и реализуется на практике (селективная реклама и т.д.). Именно на этом уровне ИИ и воспринимается массовым сознанием.

Парадоксально, но с нашей точки зрения, именно такое – во многом интуитивное – восприятие ИИ и отражает его наиболее позитивную социально-экономическую функцию. То, что сейчас называется ИИ, строго говоря есть не более чем «периферия» (в том смысле, в котором этот термин употребляют специалисты в области компьютерных наук) человеческого сознания. Совершенствование ИИ – во всяком случае до тех пор, пока не будут раскрыты механизмы функционирования сознания человека – заведомо будет относиться к «периферии» в указанном выше смысле.

Перспективнее другое. В социальном смысле ИИ будет и дальше развиваться в плане трансформации и повышения эффективности взаимодействия индивида с информационно-коммуникационной средой.

В этом смысле ИИ уже во многом занимает уникальную нишу – нишу «посредника» между надличностным уровнем переработки информации и сознанием/интеллектом индивидов. Именно в этом качестве он обещает уникальные возможности.

Поддержка исследования. Данное исследование финансируется Комитетом по науке Министерства науки и высшего образования Республики Казахстан (грант № AP14870416).

Библиографический список

1. Suleimenov, I. E., Vitulyova, Y. S., Bakirov, A. S., & Gabrielyan, O. A. (2020, April). Artificial Intelligence: what is it?. In 6th International Conference on Computer and Technology Applications (pp. 22-25).
2. Suleimenov, I.E., Gabrielyan, O.A., Massalimova, A.R., Vitulyova, Y.S. World Spirit form the standpoint of modern information theory. European Journal of Science and Theology. – 2024. – №20(1). – P. 19–31.
3. Massalimova A, Suleimenov I., Gabrielyan O., Vitulyova Y. The evolution of consciousness from the point of view of modern theory of information and telecommunications. Adam Alemi. – 2024. – №100(2). –P.40–51. <https://doi.org/10.48010/aa.v100i2.551>.
4. Pick, H., Fahoum, N., Zoabi, Detal. Brainstorming: Interbrain coupling in groups forms the basis of group creativity. Commun Biol7, 911 (2024). <https://doi.org/10.1038/s42003-024-06614-7>.
5. Габриелян, О.А., Сулейменов, И.Э. Теория сложных систем: ноосферный контекст. – Симферополь: Издательский дом ФГАОУ ВО «Крымский федеральный университет им. В.И. Вернадского», 2023. – 168 с.
6. Сулейменов И.Э., Габриелян О.А., Масалимова А.Р., Шалтыкова Д.Б., Витулева Е.С., Матрасулова Д.К. Вопрос о существовании «ментального тела» с точки зрения проблем философии // Вестник КазНУ. Серия философии, культурологии и политологии. – 2023. – Т. 84. – №. 3. – С.4.-14.
7. Габриелян О.А., Сулейменов И.Э., Габриелян А.М. Современные социальные тренды процессов обучения как трансформация интеллекта: нейросетевой подход // Социально-политические науки. – 2023. – Т.13. – №1. – С. 64-73.
8. Вигнер Е. Этюды о симметрии. – М.: Изд-во «Мир», 1971. – С. 170-181.
9. Мун Г.А., Сулейменов И.Э., Габриелян О.А., Витулёва Е.С., Кабдушев Ш.Б., Косцова М.В., Гришина А.В., Шалтыкова Д.Б. Высшее образование в цифровом обществе: использование ресурсов профессионального коллективного бессознательного // Известия НТО «Кахак». – 2021. – № 2(73). – С. 4-37.
10. Suleimenov, I. E., Gabrielyan, O. A., Bakirov, A. S., & Vitulyova, Y. S. (2019, October). Dialectical understanding of information in the context of the artificial intelligence problems. In IOP Conference Series: Materials Science and Engineering (Vol. 630, No. 1, p. 012007). IOP Publishing.

ARTIFICIAL INTELLIGENCE AS AN INTERMEDIARY BETWEEN A PERSON AND THE TRANSPERSONAL LEVEL OF INFORMATION PROCESSING

Gabrielyan Oleg Arshavirovich

V.I. Vernadsky Crimean Federal University,
Str. Yaltinskaya, 20 Simferopol, 295007, Russia
gabroleg@mail.ru

Suleimenov Ibrahim Esenovich

National Academy of Engineering of the Republic of Kazakhstan
050000, Kazakhstan, Almaty, Tulebaeva 82-21
esenych@yandex.ru

The information and communication environment is considered as a new form of existence of matter, which has a dual nature. It is in this environment that transpersonal structures are formed as a result of human communication. This interaction is described by a neural network model. Such phenomena as professional conscious and professional unconscious are defined. A hypothesis is put forward and substantiated that Artificial Intelligence opens up the possibility of interaction of human consciousness with them as with transpersonal structures.

Keywords: artificial intelligence, transpersonal structures, professional collective conscious, professional collective unconscious.

ФИЛОСОФИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: ОТ МИФА К ИНТЕГРАЛЬНОМУ ВИДЕНИЮ

Непомнящий Анатолий Владимирович

Институт компьютерных технологий и информационной безопасности
Южного федерального университета,
347922, Россия, г. Таганрог, ул. Чехова, 2
nepomnyashchiy@sfedu.ru

В статье рассматриваются философские и научные основания методологии искусственного интеллекта в их стадийной динамике – от философии и науки эпохи классицизма, свойственных для мифического и рационального сознаний, до философии и науки холистической стадии развития человеческого сознания.

Ключевые слова: философия, наука, человек, мировоззрение, методология, интегральное видение, искусственный интеллект, стадии развития, целевые функции.

Введение. Развитие информационно-коммуникационных технологий и их продуктов, от используемых в быту всевозможных гаджетов, до разработки и внедрения универсальных вычислительных платформ искусственного интеллекта открытого доступа, например ChatGPT (Chat Generative Pre-trained Transformer от OpenAI), приводит к коренной перестройке жизнедеятельности и сознания западно-ориентированной части населения Земли, не смотря на то, что это событие, как и весь спектр прочих событий, в которых участвует человек, само по себе нейтрально. Негативную или позитивную атрибутику всем событиям присваивают только их участники или их наблюдатели. И даже в таких событиях, как мировые войны, одни предают себя и других и падают вниз с библейской «лестницы Иакова», ведущей к развитию и, в пределе достижений – к Богу в себе, другие в борьбе за правое дело могут и утратить чудесный инструмент – тело, – но подняться при этом по этой лестнице ещё выше.

Но факт – есть факт: перестройка сознания и жизнедеятельности человека идёт, вместе с процессом цифровизации всего, семимильными шагами. И этот факт означает, что преобладающая часть населения подвержена, в основном, внешнему управлению и социальному программированию [4, 11], а тринитарная структура самоуправления «самоорганизация-самоконтроль-саморегуляция» не активирована в сознании масс до уровня логической оценки происходящего, т.е. до уровня развитого рационального сознания. Как следствие, можно констатировать, что социальное пророчество Рэя Брэдбери, вышедшее в свет в 1953 г. в виде его книги «451 по Фаренгейту» (температура горения бумаги), в основных своих идеологических положениях, уже сбылось и не только на территории США, как это предполагалось аналитиками, но и в большинстве других стран.

Отсюда и вытекает проблема настоящего исследования: что способствует успеху социальных программаторов, каковы, вообще, причины возникновения такой ситуации в современной западно-ориентированной цивилизации; каковы

пути её преодоления и какова роль искусственного интеллекта в этих социальных процессах?

Концептуальный анализ ситуации. Методология решения любой задачи, согласно справочникам, являет собой способы, методы, методики и средства решения задачи. Но, это определение не полное. На самом деле, методология обязательно представляет собой последовательность таких действий: определение цели; концепция её достижения (философская часть методологии); парадигма науки, способная сделать цель достижимой; аксиоматика человековедения, вытекающая из научной парадигмы; задачи, которые необходимо решить для достижения цели; и только потом способы, методы, методики и средства решения этих задач.

Определить цель происходящего, находясь в системе этого происходящего, согласно теореме К. Гёделя «О неполноте» [14], невозможно, поскольку из этой теоремы следует, что эффективное управление может быть достигнуто только в том случае, когда многообразие управляющей системы (её сложность, мерность) превышает многообразие управляемой системы или ситуации (принцип У. Эшби). И именно из факта неполноты описания мира в языке ограниченной или условно замкнутой системы и возник в науке метасистемный подход, согласно которому правильное решение по поводу функционирования системы какого-либо порядка возможно принять только наблюдателю, находящемуся в системе более высокого порядка.

Следуя этому подходу, как это делается, например в синергетике [2], необходимо выйти в своём рассмотрении на тот уровень, который включает в себя всех регуляторов происходящего: мегарегуляторов (надземные регуляторы); макрорегуляторов, управляющих глобальными процессами; микрорегуляторов – конкретных людей, их родовых и трудовых сообществ. И такие выходы сделаны Учителями человечества, показавшими человеку ту картину мира, которую они наблюдали и наблюдают, с уровнями, превышающими уровни мегарегулирования.

В качестве современного примера такого учительства можно привести деятельность и наследие воплощённого Аватара (божества) Бхагавана Шри Сатъя Саи Бабы – духовного лидера Индии, собравшего только за одну эту жизнь в человеческой форме вокруг идеи культивировать человеку Божественную (безусловную) Любовь 50 млн. преданных из разных стран мира и создавшему в Индии Интегральный университет (ныне один из ведущих вузов страны), в котором во главе всего стоит не высшая школа экономики, как это принято в западно-ориентированном обществе и образовании, а высшая школа нравственности, без чего наблюдаемый закат этой цивилизации [15] – неизбежен.

Он же и разъяснил жителям Земли, что иерархически высший регулятор, управляющий иерархией космического разума и называемый в просторечии Богом, Аллахом, Творцом всего сущего, Создателем..., проявляется в мире образовательного учреждения «Земля» в виде взаимодействия трех сил: силы созидания, силы сохранения созданного и силы растворения созданного (энтропии) [3].

В религиозном контексте человек привык превращать этот Божественный тёрнер в бинер «добро (созидание и сохранение созданного) и зло (растворение созданного)». Отсюда и ошибочный принцип в западной философии – принцип

«единства и борьбы противоположностей». На самом деле Бог сам с собой не борется, а силы растворения необходимы для того, чтобы обнаруживать изъяны в созданном, дабы продолжать его совершенствование. То есть, речь идёт не о борьбе противоположностей, а о сотрудничестве этих Божественных сил.

В итоге: силы сохранения призывают человека к реализации концепции единения, ибо единение – это повышение многообразия (сложности), а стало быть, и единственное средство развития человека и человечества, в целом, которое обретается только путем преодоления препятствий (как говорят Мудрые, «благословенны препятствия ибо ими растём»); силы растворения делают всё возможное, чтобы средствами искушения организовать те ситуации, которые проявят совершенство или несовершенство человека зададут ему, тем самым, вектор жизни – развитие (познание истины) или регресс.

Концепция сил растворения была опубликована в западном мире многократно, в частности, в труде Н. Макиавелли «Государь». Её суть – «Разделяй и властвуй» [7]. Она нашла своё отображение во всех аспектах человеческого бытия, и, прежде всего, она отобразилась в пропаганде идеи комфортной жизни. То есть, в противовес концепту «развитие через преодоление» была выдвинута теневая идея обеспечения деградации населения путём организации и пропаганды жизненного комфорта, как главной ценности. И вот здесь на сцену жизни и выходит искусственный интеллект. Совсем по В. Высоцкому: «Не надо думать! С нами тот, кто всё за нас решит!». А в результате мы имеем: рост в мировом масштабе цифровой деменции [16]; чудовищный рост невежества в массах; превращение человека в обслуживающий персонал [4, 11] и многое другое, относящееся к необратимым процессам в человеке.

Что есть «необратимый» процесс? Например, если ребёнок с его ещё недоразвитой нервной системой и мозгом (она растёт до тридцати лет, если этот процесс не останавливается алкоголем и цифровыми симуляциями) проводит время не в контакте с действительностью, а с её симуляциями в гаджетах, его мозг, как интерфейс между сознанием и телом, развивается лишь частично в тот период, который ребёнку выделен для роста когнитивных способностей. Этот период краток, и к нему невозможно вернуться. Для того чтобы потом получить полностью развитый мозг, нужно «идти» за новым телом, т.е. путём смены формы существования биологического тела и личности [5, 8]. Это хорошо иллюстрирует ситуация с даунами. Да! Как говорит К. Уилбер в своих дневниках «Один вкус» [12], «Прекрасно наблюдать в каждом дауне Будду», т.е. как говорит Библия: «Искру Бога внутри каждого из нас». Но этот Будда не может проявить себя через несовершенные инструменты – несовершенную личность, несовершенное тело и несовершенный мозг. Операцию на глазе нельзя сделать топором плотника.

Парадигмальный анализ ситуации. Руководствуясь концепцией разединения, совсем недавно (XIX в.) все науки, связанные с человековедением, были отделены от естественных наук и стали, стало быть, неестественными. Чтобы это никого не обижало и дабы не возникали лишние вопросы, эти науки называли гуманитарными, что отвлекло внимание масс от самого процесса разделения, тем более что и естественные науки стали отделять друг от друга, сначала по отраслям, затем по предметам исследования. Вследствие этого в обра-

зовании воцарился принцип мультидисциплинарности, согласно которому, по поговорке, каждый кулик мог сидеть только в своём «болоте» и только его и хвалить. Для обучающихся школьников и студентов, а также и для их учителей, и преподавателей, мир потерял свою целостность, а с ним эту целостность утратило и западно-ориентированная часть человечества. Воцарилась мифическая идея обособленности каждой особи от всего сущего, которая в эпоху постмодерна достигла своего апофеоза.

В философии постмодерна, внедрённой в США под идеологическим управлением научных институтов, занимающихся проблемой управления толпой, каждой особи внушили, что она имеет право быть главной ценностью этого мира, что у неё своя правда, которая не обязательно совпадает с правдой другого человека, и все эту правду обязаны уважать [1]. Общая правда подвергалась гонению и профессоров стали увольнять из университетов, а на их место приглашать куртизанок, рассказывающих о том, как хорошо иметь сексуальную свободу [6].

Естественно, что эта философия, в первую очередь, уничтожила образование, поскольку исчезла общая правда – интегральные образы действительности. Невозможно даже было преподавать таблицу умножения. Если преподаватель говорил, что ребёнок ошибается, говоря, что 2 умножить на 2 будет 8, родители подавали на него в суд за то, что преподаватель лишил их ребёнка права иметь свою правду. И это не шутка. По этому поводу Дж. Кулиер опубликовал статью с названием «Мы притворяемся, что учим, они притворяются, что учатся» [17].

В итоге в научном мире исчезло единое понимание смысла термина парадигма (основание), что позволило во всём западно-ориентированном мире запереть гуманитарные науки в клетке мифов классической науки, парадигма которой гласила, что масса вещества во вселенной постоянна, т.е. других субстанций кроме вещества, обладающего массой, в природе не бывает. На основе этого закона сохранения была создана аксиоматика, согласно которой человек виделся конечным в пространстве и времени, отождествлялся только с его телесной формой, личностью не рождаются, а становятся, а его сознание и психика были признаны функциями мозга. В этой аксиоматике жизнь человека потеряла всякий смысл, поскольку он появлялся ниоткуда, непонятно зачем проживал эту свою одну жизнь, и в конце её превращался в удобрение для почвы.

Эта аксиоматика привела к чудовищному падению нравственности, поскольку в ней система отдачи долгов за безнравственное поведение отсутствовала, а реклама пепси колы призывала брать от этой, якобы единственной жизни, «всё». Но в условиях, когда все хотят всего по принципу «после меня – хоть потоп», это желание взять всё нереализуемо. Отсюда войны за «иметь как можно больше» от «всёго» и решение сократить население мира до 500 млн. чел., что зафиксировано на скрижалях в штате Джорджия, оставив только обслуживающий персонал экономических «элит» [4], которые хотят, чтобы только им «всё» и принадлежало. Всех остальных должен заменить искусственный интеллект, разрабатываемый в рамках современной парадигмы, к чему всё и движется по плану, согласно которому к 2030 году искусственный интеллект (ИИ) должен стать над человеком в решении широкого спектра задач [10]. В создавшихся условиях, все вынуждены бороться за лидерство в области развития и

применения ИИ, поскольку как отметил Президент Российской Федерации В.В. Путин, кто будет лидировать в этой отрасли, тот и будет править этим миром [10]. Такой вывод логически вытекает из актуального состояния массового сознания и сознания многих гуманитариев, которые до сих пор следует мифам классической науки, потерявшей свою актуальность ещё в начале XX-го в.

В сознании масс, к сожалению, ещё не существует квантовой физики, доказавшей нелокальность квантовых эффектов, т.е. связность, а не обособленность, всего сущего, что привело к развитию на этой основе науки неклассической, парадигма которой (закон сохранения) стала включать в себя существование не только вещества, обладающего массой, но и энергии с возможности перехода одной субстанции в другую, что привело не только к развитию ядерной энергетики, но и к принятию факта существования в человеке души.

Но время и этой парадигмы давно ушло. Уже в середине прошлого века американский физик Т. Кун опубликовал свою книгу о структуре научных революций [18], в которой обратил внимание на тот факт, что в авангардном естествознании уже обнаружена и используется третья субстанция «информация». Семантическое поле смысловых значений этого понятия открыто, и в настоящее время существует более ста его смысловых значений. Из них простейшим и наиболее распространённым в технологиях создания и применения ИИ является «совокупность данных». Но данные не могут относиться к субстанциям мира, поэтому в работе Т. Куна под информацией понимается именно субстанция, обладающая управляющими свойствами, и способная переходить в энергию и массу.

В контексте этой парадигмы возникла пост-неклассическая наука, которая уже экспериментально доказала нелокальность квантовых эффектов и существование телепортации (за что только в последние пару лет было присвоено несколько нобелевских премий), а в научной модели структуры человека появился триединый Дух – его сознание, его управляющее начало [5, 8, 9].

Таким образом, пост-неклассическая наука, с применением своей основной методологии – интегрального видения [13] – доказала справедливость первого стиха в Евангелии от Иоанна, в котором и говорится, что В Начале было Слово (в более адекватном переводе Мысль) и Слово было у Бога и Слово было Бог.

Заключение. Проведенный анализ показывает, что искусственный интеллект, прошедший в своём развитии этапы использования вещества, энергии и информации, как совокупности данных, неизбежно придёт и к восприятию мысленных команд, и разработка таких компьютеров уже идет полным ходом.

Если рассматривать функциональное назначение ИИ, то оно развивается по пути от средства функционального вспоможения человеку, через средство замещения отдельных функций человека, к средству замещения самого человека.

Если человек не откажется от идеи комфортной жизни в качестве члена общества потребления и подпадёт под тотальное управление со стороны ИИ, его дни будут сочтены, поскольку космосу нужны не потребители и биологические роботы, а сотворцы, для чего человек и создавался как звено творческой космической иерархии разума.

Библиографический список

1. Бодрийяр Ж. Симулякры и симуляция//– Перевод О.А. Печенкина. – Тула, 2013. – 204 с.
2. Буданов В. Г. Методология синергетики в постнеклассической науке и в образовании. Изд. 3-е испр. – М.: Издательство ЛКИ, 2008 – 240 с. (Синергетика в гуманитарных науках).
3. Бхагаван Шри Сатья Саи Баба. Истина в афоризмах / Бхагаван Шри Сатья Саи Баба; сост. Е. Богатых. – 4-е изд. – М.: Амрита, 2012 –112 с.
4. Выступление директора НИЦ «Курчатовский институт» Михаила Валентиновича Ковальчука на заседании СФ России 30 сентября 2015 г. <http://council.gov.ru/events/news/59290/> 16.09.2024 г.
5. Гендель, М. Космоконцепция розенкрейцеров или мистическое христианство [Текст] / Г. Гендель. – Москва: Литан, 2004. – 560 с.
6. Криминалист Майк Адамс потерял работу из-за своей приверженности традиционным ценностям. Электронный ресурс: <http://www.kp.ru/daily/26179/3069073/> Дата обращения 16.09.2024 г.
7. Макиавелли Н. Государь. – М.: Планета, 1990. – 80 с.
8. Непомнящий А.В. Введение в интегральную антропологию. Ч.1: Методология знания и методологические основания человековедения: Учебное пособие. – Ростов-на Дону: Таганрог: Изд-во ЮФУ, 2021. – 312 с. <https://hub.sfedu.ru/repository/material/801298485/>
9. Непомнящий А.В. Введение в интегральную антропологию. Ч.2: Деятельность человека, управление деятельностью и её безопасность. Учебное пособие. – Ростов-на Дону: Таганрог: Изд-во ЮФУ. – 2023. – 306 с. <https://hub.sfedu.ru/repository/material/801325716/>
10. Совещание по вопросам развития технологий в области ИИ, 30 мая 2019 г. в «Школе 21» Сбербанка. <http://kremlin.ru/events/president/news/60630> Дата обращения: 16.09. 2024 г.
11. Толкунов А. Похитители разума – М: Советская Россия, 1980. – 96 с.
12. Уилбер К. Один вкус: Дневники Кена Уилбера / К. Уилбер; Пер. с англ. А. Киселева. – М: ООО «Издательство АСТ» и др., 2004. – 427, [5] с. – (Тексты трансперсональной психологии).
13. Уилбер К. Око духа: Интегральное видение для слегка свихнувшегося мира/ К. Уилбер /Пер с англ. В. Самойлова под ред. А. Киселева. – М.: ООО «Издательство АСТ» и др., 2002. – 476. [4] с.
14. Успенский В.А. Теорема Гёделя о неполноте. – М.: Наука. 1982. – 112 с.
15. Шпенглер О. Закат западного мира; Очерки морфологии мировой истории. Полное издание в одном томе/Пер. с нем. – М.: «Издательство АЛЬФА-КНИГА», 2014. – 1085 с. ил.
16. Шпитцер Манфред. Антимозг: цифровые технологии и мозг/ Манфред Шпитцер; пер. с немецкого А. Г. Гришина – Москва: АСТ, 2014. – 288 с.
17. Collier G.L. (2013) We Pretend to Teach, They Pretend to Learn – WSJ, 2013 <https://www.wsj.com/articles/we-pretend-to-teach-they-pretend-to-learn-1388103868> (дата обращения 16.09.2024).
18. Kuhn T.S. The Structure of Scientific Revolutions. Chicago, 1962; Москва, 1975.

ARTIFICIAL INTELLIGENCE PHILOSOPHY: FROM MYTH TO INTEGRAL VISION

Anatoly V. Nepomnyashchiy

Institute of Computer Technology and Information Security
Southern Federal University,
2 Chekhova St., Taganrog, Russia 347922
nepomnyashchiy@sfedu.ru

The article examines the philosophical and scientific foundations of the methodology of artificial intelligence in their stage dynamics – from the philosophy and science of the era of classicism, characteristic of the mythical and rational consciousness, to the philosophy and science of the holistic stage of human consciousness development.

Key words: philosophy, science, human, worldview, methodology, integral vision, artificial intelligence, stages of development, target functions.

ФИЛОСОФСКОЕ ОСМЫСЛЕНИЕ: ИНТЕЛЛЕКТ ЧЕЛОВЕКА И МАШИНЫ

*Гибадуллин Валерий Сагитович, Дмитриев Владимир Геннадьевич,
Галиева Алина Искандаровна, Галиева Галия Искандаровна*

Уфимский государственный нефтяной технический университет,
450062, Россия, г. Уфа, ул. Космонавтов, 1.
gvs5701@mail.ru, dmitrievova@yandex.ru,
alinagalieva18@yandex.ru, alga4@mail.ru

В статье рассматриваются вопросы и проблемы в области человеческого и искусственного интеллекта, некоторые аспекты их взаимоотношений и перспективы развития.

Ключевые слова: искусственный интеллект, разум, цивилизация, информационные технологии, мышление, проблема, структура, программы, алгоритм.

Философское осмысление проблемы искусственного интеллекта имеет своим истоком мысль о сходстве искусственного разума и человеческого интеллекта и задаётся вопросами осмысления взаимоотношений человека и машины, соотношения человеческого и машинного разума. Эти вопросы отражают интересы различных исследователей искусственного интеллекта. Ответы зависят от того, что понимается под интеллектом.

Есть разные точки зрения. Существует определение интеллекта, как отношение организма к предметной среде, или как способность решать интеллектуальные задачи. Некоторые специалисты за интеллект принимают способность рационального мотивированного выбора, в условиях недостатка информации, или же способности системы создавать в ходе самообучения программы для решения задач и решать эти задачи.

Часть исследователей рассматривают искусственный интеллект как технологию, которая имитирует деятельность человека и может обладать свойством выполнять творческие функции и др.

Есть ещё много попыток интерпретации интеллекта. Однако формулировки не являются строго научными и общепризнанными, общепонятными и исчерпывающими, поскольку это развивающееся и доопределяющееся явление и сложившееся представления о нём меняются. В том числе, благодаря новейшим разработкам в области технологий оптических изображений отделов головного мозга, позволяющих исследовать его в процессе функционирования. Тем самым обратить внимание в структуре интеллекта на его психическую составляющую называемую эмоциональный интеллект. То есть его способности воспринимать контролировать и оценивать чувства, эмоции, поведение. На наш взгляд искусственный интеллект на сегодняшний день достаточно рассматривать пока только как инструмент разума.

Теперь попробуем понять тождественны ли понятия «интеллект» и «разум». Если есть эти два термина, то вероятно они обозначают явления в чем-то схожие, но не тождественные.

Гаджеты, дивайсы, multifunctional приложения и новинки электроники, в том числе, используемые в сфере интеллектуальной деятельности содержат в себе некоторые, порою весьма существенные зачатки искусственного интеллекта.

С нашей точки зрения интеллект – это то, что способно обработать информацию на основании уже существующей опорной информационной базы и выдавать рекомендации по заложенному в него алгоритму. Мозг тоже использует алгоритмы, однако эти алгоритмы являются совершенно не регулярными. Ожидать, что ему (искусственному интеллекту) можно доверять принятия ваших решений с нашей точки зрения пока преждевременно.

Признать превосходство искусственного интеллекта означает расписаться в признании собственной неспособности принимать решения, размывать, делегировать свою ответственность и жить, чужим цифровым разумом, вдобавок, ещё и не доказавшим свою компетентность.

Как цивилизация подошла к потребности включить искусственный интеллект в ход дальнейшего своего развития и зачем. Сначала про интеллект в целом. Примем за условную 1 (100%) средний уровень интеллекта отдельного человека. Тогда окажется, что разброс этого уровня может быть в диапазоне от 0,1 до 10 ед. (в случае гениев и гораздо больше)

Фрагменты искусственного интеллекта уже прочно вошли в жизнь общества в виде программированных манипуляторов, специализированных автономных моделей, распознавателей речи и лиц, виртуальных ассистентов, навигационных систем и т.п.

Вопрос только в том, удастся ли разработчикам на этой основе создать глобальную сеть искусственного интеллекта и с какими опасениями наличие такой сети будет связано.

Ученые в массе своей больше идеалисты, по части применения научных открытий и достижений, а политики – прагматики и они понимают, что искусственный интеллект уже сегодня является символом власти. С учётом всех существующих на сегодня конфликтов, а именно военных, экономических, торговых, политических в чем может проявиться вклад глобального искусственного интеллекта в дальнейшее развитие или деградации цивилизации, которая уже и так находится на грани стабильности.

Будет ли искусственный интеллект чем-то глобальным, или потенциальные соперники в рамках своих национальных систем разработают свои «развитые» программные алгоритмы, тоже соперничающие между собой.

Как господь Бог создал человека по образу и подобию своему и вложил в него разум (как утверждает Библия), так и программисты будут проектировать искусственный интеллект, опираясь на свои знания и представления. А они – знания и представления – не будут у всех тождественными. И чтоб имитировать человеческий разум надо быть все же выше этого разума.

В английской этимологии словосочетание ИИ (AI) «artificial intelligence» не несёт той, слегка антропоморфной окраски, которое оно приобрело в довольно неудачном русском переводе. Слово «intelligence» означает «умение рассуждать разумно», а вовсе не интеллект, для которого существует английский аналог «intellect».

Основная философская проблема в области искусственного интеллекта заключается в доведении возможности и целесообразности моделирования процесса мышления человека, хотя до сих пор, мы не можем определить какие процедуры хотим назвать интеллектуальными. И вообще, интеллект был, есть и может остаться только биологическим феноменом.

В этой связи существует опасность тратить время и средства на изучение того, что так и останется нашей иллюзией, что невозможно создать и понадобится десятилетия и больше, чтобы хотя бы приблизиться к уровню человека разумного, но, в конце концов, и такое может произойти.

Библиографический список

1. С. Хокинг. Вселенная Стивена Хокинга. – Москва: АСТ, 2018 – 160 с.
2. Пенроуз Р. Новый ум короля. – М.: Едиториал УРСС, 2003. – 339 с.
3. Винер Н. Кибернетика, или Управление и связь в животном мире. – М. Советское радио, 1968.

PHILOSOPHICAL UNDERSTANDING: HUMAN AND MACHINE INTELLIGENCE

***Gibadullin Valery Sagitovich, Dmitriev Vladimir Gennadievich,
Galieva Alina Iskandarovna, Galieva Galiya Iskandarovna***

Ufa State Petroleum Technical University,
1, Kosmonavtov str., Ufa, 450062, Russia.
gvs5701@mail.ru, dmitrievova@yandex.ru,
alinagalieva18@yandex.ru, alga4@mail.ru

The article discusses issues and problems in the field of human and artificial intelligence, some aspects of their relationship and prospects for development.

Keywords: artificial intelligence, mind, civilization, information technology, thinking, problems of artificial intelligence.

ИСКУСТВЕННЫЙ ИНТЕЛЛЕКТ: ВОЕННОЕ ПРИМЕНЕНИЕ

Фиговский Олег Львович

Ассоциация изобретателей Израиля

Израиль, г. Тель-Авив

figovsky@gmail.com

В статье рассмотрены вопросы применения и контроля искусственного интеллекта в военных целях.

Ключевые слова: Искусственный интеллект, военное использование, контроль над применением.

Одна из проблем, связанная с прогнозированием контроля над конкретными применениями военного ИИ, заключается в неясности того, как ИИ в конечном итоге будет использоваться на поле боя. Поэтому сейчас сложно накладывать какие-либо ограничения. По мере развития искусственного интеллекта некоторые высказывают опасения по поводу систем вооружения с использованием ИИ. В связи с этим возникает вопрос о том, насколько реально контролировать военное использование.

Вооруженные силы по всему миру работают над разработкой, интеграцией и использованием ИИ в своих системах вооружений. Хотя многие из этих систем еще не реализованы, прорывы в области ИИ могут со временем оказать значительное влияние на функционирование вооруженных сил. Беспокойство по поводу военных систем ИИ заставило некоторых активистов призывать к запрету или регулированию систем вооружения с использованием ИИ.

Тем не менее, ИИ обладает рядом характеристик, которые затрудняют контроль над ним. Будучи технологией общего назначения, ИИ подобен электричеству или двигателю внутреннего сгорания и имеет бесчисленное множество невоенных и оборонных применений. Он отличается от некоторых военных технологий тем, что разрабатывается преимущественно в гражданском секторе инженерами в частной промышленности или в исследовательских организациях. Хотя широкое распространение ИИ делает маловероятным полный запрет на все военные применения ИИ, у международного сообщества может быть возможность совместной работы по регулированию или запрету определенных видов использования военного ИИ.

Пентагон представил стратегию внедрения искусственного интеллекта в военный сектор для улучшения принятия решений на поле боя. Разработанная Главным управлением по цифровым технологиям и ИИ (CDAO), она предусматривает улучшение данных, сотрудничество с внешними группами и использование ИИ для анализа сил и противодействия киберугрозам. В ней также акцентируется внимание на потенциальной опасности ИИ в автономном ору-

жии, из-за чего была обновлена соответствующая директива. Появление больших языковых моделей (БЯМ) подстегнуло интерес к интеграции ИИ в процессы принятия решений по самым серьезным внешнеполитическим вопросам. Исследователи из США изучили действия ИИ в специально разработанной стратегической видеоигре, уделив особое внимание склонности к эскалации конфликтов. Все языковые модели, сыгравшие в эту игру, предпочли мирному урегулированию гонку вооружений, нанесение превентивных ударов и применение ядерного оружия. Ни одна из моделей не показала склонности к деэскалации. Летом прошлого года агентство Bloomberg сообщило о проведении Пентагоном испытаний по оценке способностей БЯМ к эффективному планированию в сценариях военных конфликтов. По словам одного из участников этих «учений», полковника ВВС Мэтью Стромайера, БЯМ «могут быть применены военными в самое ближайшее время». В этом случае они заменят другие системы ИИ, которые сейчас использует Министерство обороны США, к примеру, проект Maven. При этом досконального понимания возможностей и ограничений БЯМ ни у военных, ни у самих разработчиков нет.

Председатель Комитета начальников штабов Вооруженных сил США генерал армии Марк Милли, выступая на конференции, назвал искусственный интеллект одной из самых мощных технологий, которые сейчас развивает человечество. По его мнению, использование ИИ в военных целях дает как минимум преимущество в скорости принятия решений, опережающих действия и даже планы противника. Возможность принимать те или иные решения быстрее и точнее является важным преимуществом в ведении войны. Искусственный интеллект и квантовые вычисления дадут такое преимущество стране, которая преуспеет в их военном применении, – уверен Милли. Ранее известный американский бизнесмен Илон Маск высказывал опасения по поводу последствий от бесконтрольного развития нейросетей и внедрения функций искусственного интеллекта во все большие сферы человеческой деятельности. Владелец Tesla и SpaceX вместе с соучредителем компании Apple Computer Стивом Возняком и еще 1400 представителями IT-отрасли подписали открытое письмо, призывающее на время остановить масштабные эксперименты с искусственным интеллектом и нейросетями. Американский миллиардер Уоррен Баффет сравнил развитие самообучающихся нейросетей с созданием ядерного оружия, но при этом скептически оценил перспективы, что искусственный интеллект в скором времени заменит человека.

По-настоящему автономных систем на современных полях сражений немного, но американский стартап Swarmbotics хочет успеть стать одним из первых поставщиков роботизированной системы. Ее особенность – в децентрализованном коллективном поведении, которое иначе называют роевым. Система ANTS, которую разрабатывает компания, должна сделать военную логистику проще и безопаснее. Стартап Swarmbotics основали два специалиста по автономным системам, которые прежде занимались разработкой робогрузовиков в компании Embark Trucks. К тому же один из них служил в морской пехоте, а второй сотрудничал с ЦРУ и Лабораторией реактивного движения NASA. Стивен Хьютон, один из основателей стартапа, так объяснил изданию

TechCrunch свою одержимость роем роботов: в частном секторе большая часть капитала и времени уходит на разработку очень дорогих автономных систем, таких как роботакси, которые должны получиться практически совершенными, чтобы выполнять свои задачи. Менее ресурсоемкие и идеальные роботы можно было бы изготавливать быстрее и дешевле.

Роевой интеллект – относительно новая сфера исследований, которая в основном занята проектированием БПЛА. У наземных аппаратов есть свои преимущества и недостатки: с одной стороны, по поверхности труднее передвигаться, зато наземной технике требуется меньше энергии, а ее грузоподъемность больше. Поэтому Swarmbotics начала с проектирования двух моделей: более крупный гибридный автономный колесный транспорт Haul ANT и Fire ANT меньшего размера. Оба, по сути, аккумуляторы на колесах. Стартап предоставляет только транспортную платформу, на которую заказчик может монтировать что угодно, от систем разведки и РЭБ до вооружения. Но главное преимущество этих роботов – в количестве, когда они начинают действовать сообща и обмениваться информацией. Это значит, что они должны быть относительно дешевыми. В первую очередь, это относится к датчикам. Swarmbotics не пытаются использовать наиболее производительные датчики, стартап отталкивается от бюджета потенциального заказчика – Пентагона – и пытается разработать достаточно эффективную децентрализованную систему в рамках выделенных средств.

Государства будут сопротивляться регулированию оружия с высокой военной ценностью – такого, которое эффективно, предоставляет уникальный доступ или обеспечивает решающее преимущество на поле боя, – даже если это оружие способно причинить существенный вред. Военная ценность оружия кладется на разные чаши весов с его теоретическим вредом, имеющим место, если оружие воспринимается как бесчеловечное, неизбирательное, дестабилизирующее или разрушающее политический или социальный порядок.

Библиографический список

1. Фиговский Олег. Новые технологии и наука в современном мире (монография, том 2). ВОИР, Севастополь, 2023, стр. 333.
2. Фиговский Олег: Военные технологии и космос. «Сретенский клуб», Москва. 09.11.2020.
3. Фиговский Олег: Современные военные технологии. «Атомная Стратегия», Санкт Петербург. 27/07/2022.

ARTIFICIAL INTELLIGENCE: MILITARY APPLICATION

Oleg L. Figovsky

Association of Inventors of Israel
Israel, Tel Aviv
figovsky@gmail.com

The article examines the issues of application and control of artificial intelligence for military purposes.

Keywords: Artificial intelligence, military use, control over application

ВОПРОСЫ ЭТИКИ И ОТВЕТСТВЕННОСТИ ПРИ РАЗРАБОТКЕ И ВНЕДРЕНИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Зотина Галина Витальевна

Пермский государственный национальный исследовательский университет
614068, Россия, г. Пермь, ул. Букирева, 15
pastuhova13@yandex.ru

Патакина Анастасия Сергеевна

Академическая школа информационных технологий
614002, Россия, г. Пермь, ул. Чернышевского, 28
patakina@gmail.com

Искусственный интеллект (ИИ) в последние десятилетия превратился из научной фантастики в технологию, способную значительно преобразовать все аспекты человеческой жизни и активно внедряется повсеместно, что делает его одним из ключевых двигателей технологического прогресса. Однако, наряду с огромными возможностями, возникают и серьёзные вызовы, касающиеся этики и ответственности при разработке и применении этой технологии, данные вопросы и поднимаются в статье.

Ключевые слова: нейросетевые технологии, этика искусственного интеллекта, машинное обучение.

Всюду по-прежнему был виден порядок,
поистине сложная соотнесенность частей становилась
совершеннее, все утонченнее и пленительней,
но разросшиеся кроны начали загораживать небо.
А.Азимов, Вид с высоты

Введение. Весной 2018 года компания Uber тестировала беспилотный автомобиль на базе одной из моделей Volvo на улицах города Темп в штате Аризона, США. Машина сбила женщину насмерть, тестирование автопилота проводилось при сниженной чувствительности к распознанным опасным объектам, чтобы избежать ложных срабатываний. Tesla зафиксировала уже два дорожных инцидента со смертельным исходом – в 2016 и 2018 годах. Очевидно, что это только начало и самое фатальное в сложившихся обстоятельствах – это непредсказуемость для человека. Об актуальности вопросов этики и ответственности искусственного интеллекта говорит и тот факт, что проблема ошибок данной технологии в юриспруденции уже квалифицируется как обстоятельства непреодолимой силы (форс-мажор), кстати, к последним относятся и стихийные бедствия.

Предвзятость алгоритмов. Одним из ключевых вызовов в сфере искусственного интеллекта является проблема предвзятости алгоритмов. Еще со времен машин Луллия процесс познания мира за счет сведения к логическим операциям уже грешил предвзятостью [1]. Алгоритмы, особенно те, которые используют методы машинного обучения, обучаются на больших наборах данных, которые могут содержать систематические ошибки или предвзятые представления [2]. В результате, такие алгоритмы могут воспроизводить и усили-

вать существующие социальные предвзятости, что приводит к неравенству и дискриминации в различных областях применения, о чем свидетельствует история с корпорацией Amazon и экспериментом по анализу резюме.

Предвзятость алгоритмов может иметь различные источники, которые условно можно разделить на три категории: предвзятость данных, предвзятость модели и предвзятость применения.

1. *Предвзятость данных*: в основе большинства алгоритмов машинного обучения лежат исторические данные, которые могут содержать предвзятости, унаследованные от социальных, экономических или культурных контекстов, в которых они были собраны. Например, если алгоритм, предназначенный для отбора кандидатов на работу, обучен на данных, в которых доминируют мужчины, то он может воспроизводить гендерную предвзятость, исключая женщин из числа подходящих кандидатов.

2. *Предвзятость модели*: алгоритмическая предвзятость также может быть следствием выбора или структуры модели. Алгоритмы могут быть спроектированы таким образом, что они непреднамеренно усиливают предвзятости, заложенные в данных. Например, использование неадекватных метрик или функций потерь может привести к тому, что модель будет оптимизирована для одних групп, но будет систематически занижать результаты для других.

3. *Предвзятость применения*: даже если алгоритм сам по себе свободен от предвзятости, его применение в реальных условиях может привести к нежелательным последствиям. Например, алгоритм кредитного скоринга, который оценивает платёжеспособность клиентов, может быть использован финансовыми учреждениями так, что будут исключены определённые социальные группы, а это приведёт к ухудшению их экономического положения.

Борьба с проблемой предвзятости алгоритмов требует комплексного подхода, включающего разнообразие данных, мониторинг моделей, участие общественности и введение соответствующих нормативов.

Конфиденциальность данных. В условиях стремительного роста объемов данных и увеличения количества взаимодействий между людьми и ИИ-системами вопрос защиты личной информации набирает обороты. Алгоритмы часто требуют доступа к значительным объемам данных для своего обучения и функционирования, тем самым ставит перед обществом вопросы в сфере обеспечения конфиденциальности и безопасности информации.

Нарушение конфиденциальности данных может иметь серьёзные последствия для пользователей, включая утрату контроля над личной информацией, угрозу безопасности, дискриминацию и даже финансовые потери. Например, если персональные данные пациентов утекут из медицинской системы, это может привести к нарушениям прав на частную жизнь, а также к возможности использования этих данных в недобросовестных целях.

Алгоритмы искусственного интеллекта, основанные на больших данных, представляют собой особую угрозу конфиденциальности, так как часто использует персональные данные для анализа и прогнозирования. В частности, алгоритмы, предназначенные для предсказания поведения или предпочтений пользователей, могут привести к созданию детализированных профилей, которые содержат большое количество конфиденциальной информации [3; 6]. Это от-

крывает возможности для использования таких профилей в манипулятивных целях, например, в политической рекламе или в маркетинге, направленном на уязвимые группы.

В ряде стран уже приняты и действуют законы, направленные на защиту личной информации, такие как Общий регламент по защите данных (GDPR) в Европейском союзе. Эти нормативные акты устанавливают строгие требования к обработке персональных данных, включая необходимость получения явного согласия на их использование, право на удаление данных и обязательства по уведомлению в случае утечек.

Законодательное регулирование играет ключевую роль в установлении стандартов и практик, направленных на защиту конфиденциальности данных. Это включает в себя не только требования к компаниям и организациям, которые обрабатывают данные, но и меры по обеспечению ответственности за нарушения.

Ответственность за решения ИИ. Распределение ответственности за решения искусственного интеллекта представляет собой сложную задачу, поскольку ИИ-системы часто являются результатом взаимодействия множества субъектов, включая разработчиков, поставщиков данных и пользователей. В этом контексте возникает ряд ключевых вопросов:

1. **Ответственность разработчиков:** разработчики играют ключевую роль в создании и настройке алгоритмов. Они несут ответственность за качество и корректность кода, а также за соблюдение этических норм и стандартов при разработке ИИ-систем. Однако, поскольку ИИ-системы могут быть автономными и обучаться на данных, которые не всегда полностью контролируются разработчиками, ответственность за возможные ошибки или предвзятость становится размытой.

2. **Ответственность поставщиков данных:** качество данных, используемых для обучения, напрямую влияет на его поведение и принимаемые решения. Если данные содержат ошибки или предвзятость, это может привести к некорректным выводам. Вопрос о том, кто несёт ответственность за использование таких данных, остаётся открытым и требует ясного регулирования.

3. **Ответственность пользователей:** пользователи ИИ-систем, особенно те, кто принимает решения на основе рекомендаций, также могут нести ответственность за последствия. Однако степень этой ответственности может варьироваться в зависимости от уровня контроля над системой и степени автономности. В некоторых случаях пользователи могут не осознавать рисков, связанных с использованием ИИ-систем, что ставит под сомнение их способность нести полную ответственность.

4. **Ответственность самих ИИ-систем:** идея о том, что ИИ-системы могут нести самостоятельную ответственность за свои действия, является предметом активных дискуссий в научных кругах. Пока что такая ответственность остаётся теоретической, так как искусственный интеллект не обладает правосубъектностью и не может быть субъектом права. Однако с развитием технологий автономности ИИ-систем этот вопрос может потребовать нового правового подхода.

На международном уровне всё ещё не существует единых стандартов и норм, регулирующих ответственность за решения, принятые ИИ-системами.

Прозрачность и объяснимость.

Прозрачность подразумевает, что пользователи и заинтересованные стороны могут получить доступ к информации о том, как работает ИИ-система, какие данные использовались для её обучения, и как были настроены алгоритмы.

Объяснимость ИИ-систем – это способность системы демонстрировать алгоритмы работы, предоставлять ясные и доступные для понимания объяснения своих решений [4]. Это особенно сложно в случае с высокоуровневыми моделями, такими как глубокие нейронные сети, которые часто действуют как «чёрные ящики». Основные вызовы объяснимости включают:

1. **Сложность моделей:** Многие современные ИИ-системы, такие как глубокие нейронные сети, обладают высокой сложностью, что затрудняет их интерпретацию.

2. **Компромисс между объяснимостью и точностью:** Существует компромисс между сложностью модели и её объяснимостью. Простые модели, такие как линейные регрессии или деревья решений, могут быть легко интерпретированы, но они могут уступать в точности более сложным моделям. В то же время, более сложные модели могут быть более точными, но их интерпретация требует значительных усилий и специальных знаний.

3. **Культурные и когнитивные различия:** Способность к пониманию объяснений может различаться в зависимости от аудитории. Пользователи с разным уровнем знаний и из разных культур могут по-разному воспринимать одно и то же объяснение. Это усложняет задачу создания универсальных методов объяснимости, которые были бы понятны всем пользователям.

Для обеспечения прозрачности и объяснимости ИИ разработаны различные подходы и методы:

1. **Интерпретируемые модели:** один из способов обеспечения объяснимости – использование интерпретируемых моделей, таких как линейные регрессии, деревья решений или простые байесовские классификаторы. Эти модели более прозрачны и их результаты могут быть легко объяснены пользователям. Однако такие модели не всегда могут обеспечить необходимую точность в сложных задачах.

2. **Пост-хок объяснения:** для сложных моделей разработаны методы пост-хок объяснений, которые предоставляют интерпретацию решений после их принятия. К таким методам относятся, например, LIME (Local Interpretable Model-agnostic Explanations) и SHAP (SHapley Additive exPlanations), которые объясняют решения, показывая, какие признаки внесли наибольший вклад в результат [5].

3. **Визуализация данных и моделей:** визуализация – ещё один мощный инструмент для обеспечения прозрачности и объяснимости. Визуализация может помочь пользователям лучше понять, как алгоритм анализирует данные и принимает решения. Такие инструменты, как тепловые карты, графики значимости признаков и интерактивные панели, могут значительно облегчить интерпретацию результатов.

4. Тестирование и аудит: регулярное тестирование и аудит ИИ-систем на предмет их объяснимости и прозрачности также являются важными аспектами. Включение независимых экспертов и представителей общественности в эти процессы может помочь выявить недостатки и улучшить систему.

Исследования, проведенные KPMG и опубликованные на Springer, демонстрируют значимость таких подходов для минимизации рисков и повышения доверия пользователей к ИИ-системам.

Этика и ответственность в области искусственного интеллекта являются ключевыми аспектами, определяющими не только будущее этой технологии, но и её влияние на общество в целом. Важно создавать и внедрять такие нормы и стандарты, которые бы гарантировали справедливость, безопасность и защиту прав человека при использовании ИИ-систем. Это включает в себя необходимость внедрения ответственных практик разработки, обеспечения прозрачности и объяснимости алгоритмов, а также создание правовых рамок, которые помогут определить и распределить ответственность за действия искусственного интеллекта.

Библиографический список

1. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
2. Floridi, L., & Cowls, J. (2019). A Unified Framework of Five Principles for AI in Society.
3. Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate.
4. Binns, R. (2018). Fairness in Machine Learning: Lessons from Political Philosophy.
5. Crawford, K., & Calo, R. (2016). There is a blind spot in AI research.
6. Doshi-Velez, F., & Kim, B. (2017). Towards A Rigorous Science of Interpretable Machine Learning.

ISSUES OF ETHICS AND RESPONSIBILITY IN THE DEVELOPMENT AND IMPLEMENTATION OF ARTIFICIAL INTELLIGENCE

Zotina Galina Vitalievna

Perm State National Research University,
15 Bukireva str., Perm, 614068, Russia
pastuhova13@yandex.ru

Patakina Anastasia Sergeevna

Academic School of IT,
28 Chernyshevsky str., Perm, Russia, 614002
patakina@gmail.com

In recent decades, artificial intelligence (AI) has transformed from science fiction into a technology capable of significantly transforming all aspects of human life and is being actively implemented everywhere, which makes it one of the key engines of technological progress. However, along with huge opportunities, serious challenges arise regarding ethics and responsibility in the development and application of this technology, and these issues are raised in the article.

Keywords: neural network technologies, ethics of artificial intelligence, machine learning.

ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В НАУЧНОЙ И ИННОВАЦИОННОЙ ДЕЯТЕЛЬНОСТИ

Тобиен Мария Александровна

Владимирский государственный университет им. А.Г. и Н.Г. Столетовых,
600000, Россия, г. Владимир, ул. Горького, 87
kalinina_m5a@mail.ru

Базу инновационной экономики формируют цифровые технологии, которые обеспечивают эффективную работу с различной информацией, стабильное функционирование инновационной инфраструктуры, новейшие цифровые сервисы для всех участников инновационного процесса. К таким технологиям можно отнести и искусственный интеллект. В статье представлена статистика применения данной технологии в научной и инновационной сферах.

Ключевые слова: искусственный интеллект, цифровая трансформации, инновационная деятельность, наука, инновации.

Введение. В условиях всемирного развития информационно-коммуникационных технологий и их глубокого проникновения во все сферы жизни общества происходит трансформация мировой и национальных экономических систем. Важнейшие глобальные факторы трансформации указанных систем хозяйствования в эпоху цифровизации представлены на рис. 1.

Таким образом, происходящие в настоящее время процессы во всех сферах жизни общества можно охарактеризовать таким термином как «цифровая трансформация». Цифровая трансформация происходит как на уровне стран и регионов, так и на уровне отдельных предприятий.



Рис. 1. Факторы трансформации национальных и мировой систем хозяйствования в эпоху цифровизации

Искусственный интеллект как основа цифровой трансформации в научной и инновационной сферах. Современная инновационная экосистема как часть социально-экономической системы также претерпевает значительные изменения. Глобальный процесс инновационного соперничества вынуждает компании внедрять цифровые технологии в свою деятельность, активно применять цифровые сервисы и развивать информационную инфраструктуру. Одними из популярных на сегодняшний день цифровых технологий являются технологии искусственного интеллекта (далее-ИИ). ИИ – это «комплекс методик математики, биологии, психологии, кибернетики и других наук, с помощью которого создаются технологии для написания «умного» программного обеспечения и обучения ПК самостоятельному решению сложных задач» [7].

Согласно данным статистического сборника «Индикаторы цифровой экономики: 2024» в 2022 году технологии ИИ применяли в своей деятельности 6,6% организаций, что почти на 16% выше значений прошлого периода (рис. 2).




Рис. 2. Использование цифровых технологий в организациях в % от общего числа организаций [9]

Наибольшей популярностью за указанный период пользовались технологии сбора, обработки и анализа больших данных (30,4%), 28,9% обследуемых компаний использовали облачные сервисы 16,5% – центры обработки данных и почти 15% – цифровые платформы.

Что касается научной сферы, то в 2022 году технологии ИИ использовали 3,9% организаций (рис. 3). Самыми востребованными для научно-исследовательских организаций оказались «облачные сервисы» (23,6%), а также «технологии сбора, обработки и анализа больших данных» (20,6%) [2].

Согласно мониторингу развития и распространения искусственного интеллекта, проведенного экспертами НИУ ВШЭ (было обследовано более двух тыс. компаний – пользователей продуктов на основе ИИ), более половины респондентов (54,9%) считают, что основные выгоды, связанные с внедрением ИИ заключаются в модификации имеющихся продуктов; 31,6% организаций указали, что с помощью данной технологии создаются организационные нов-

шества; 21,6% компаний искусственный интеллект применяют для вывода инновационной продукции на отечественный рынок; новые в мировом масштабе товары и услуги реализуют только 4,6% опрошенных предприятий (рис. 4).



Рис. 3. Использование цифровых технологий в организациях, занятых научной и технической деятельностью в 2022 году, в % от общего числа организаций




Рис. 4. Доля организаций, указавших цели инновационной деятельности, связанные с внедрением ИИ на начало 2023 года (в% от числа организаций-пользователей ИИ [3])

60% обследованных организаций применяют технологии ИИ для осуществления исследований и разработок. Также многие опрошенные предприятия реализуют инновации на базе данной передовой технологии, например, создают программное обеспечение и базы данных (52,5%), различные маркетинговые инструменты (39,8%) или занимаются инжинирингом (17%) (рис. 5).

Заключение. Таким образом, в настоящее время технологии ИИ стали важнейшей составляющей жизни общества. Они проникли во многие сферы, включая науку и инновационную деятельность. Решения на основе ИИ дают возможность автоматизировать стандартные задачи, развивать новые форматы коммуникаций, внедрять инновационные бизнес-модели, осваивать новые рыночные ниши и др.




Рис. 5. Доля организаций, осуществляющих отдельные виды инновационной деятельности, связанные с внедрением ИИ (% от числа организаций-пользователей ИИ [3]).

Библиографический список

1. Белло, М. и Ф. Галиндо-Руэда (2020), «Схема цифровой трансформации науки: результаты Международного опроса научных авторов ОЭСР 2018 года (ISSA2)», Рабочие документы ОЭСР по науке, технологиям и промышленности, № 2020/03, Издательство ОЭСР, Париж, <https://doi.org/10.1787/1b06c47c-en>
2. Индикаторы цифровой экономики: 2024: статистический сборник / В.Л. Абашкин, Г.И. Абдрахманова, К.О. Вишневский, Л.М. Гохберг и др.; Иб0 Нац. исслед. ун-т «Высшая школа экономики». – М.: ИСИЭЗ ВШЭ, 2024. – 276 с.
3. Искусственный интеллект в России: векторы инноваций. [Электронный ресурс]. – Режим доступа: <https://issek.hse.ru/news/862014108.html>
4. Приказ Минкомсвязи России от 01.08.2018 N 428 «Об утверждении Разъяснений (методических рекомендаций) по разработке региональных проектов в рамках федеральных проектов национальной программы «Цифровая экономика Российской Федерации»
5. Рейтинг цифровых компаний по числу «цифровых» патентов. [Электронный ресурс]. – Режим доступа: <https://issek.hse.ru/news/838422953.html>
6. Синева Н.Л., Вагин Д.Ю., Лебедева О.А., Туманова А.О., Оленина Л.А. Инновационно-технологическое развитие и искусственный интеллект // Инновационная экономика: перспективы развития и совершенствования. 2019. №2 (36). [Электронный ресурс]. – Режим доступа: <https://cyberleninka.ru/article/n/innovatsionno-tehnologicheskoe-razvitie-i-iskusstvennyy-intellekt>
7. Технологии искусственного интеллекта и машинного обучения. [Электронный ресурс]. – Режим доступа: <https://hsbi.hse.ru/articles/tekhnologii-iskusstvennogo-intellekta-i-mashinnogo-obucheniya/>
8. Цифровая трансформация науки. [Электронный ресурс]. – Режим доступа: https://atomicexpert.com/digital_transformation_of_science
9. Цифровая экономика: 2024 : краткий статистический сборник / В.Л. Абашкин, Г.И. Абдрахманова, Ц75 К.О. Вишневский, Л.М. Гохберг и др.; Нац. исслед. ун-т «Высшая школа экономики». – М. : ИСИЭЗ ВШЭ, 2024. – 124 с.

USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGYS IN SCIENTIFIC AND INNOVATIVE ACTIVITIES

Maria A. Tobien

Vladimir State University named after Alexander and Nikolay Stoletovs,
Gorkogo st., 87, Vladimir, Russia, 600000 kalinina_m5a@mail.ru

The basis of the innovation economy is formed by digital technologies that ensure efficient work with various information, uninterrupted functioning of the innovation infrastructure, new digital services for all participants in the innovation process. Artificial intelligence can also be attributed to such technologies. The article presents statistics on the use of this technology in the scientific and innovation spheres.

Keywords: artificial intelligence, digital transformation, innovation activities, science, innovation.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И РАЗРЫВЫ ОТВЕТСТВЕННОСТИ: ВЫЗОВЫ, РИСКИ И ЭТИЧЕСКИЕ ДИЛЕММЫ АВТОНОМНЫХ СИСТЕМ

Титов Владислав Дмитриевич

Волгоградский государственный университет
400062, Россия, г. Волгоград, просп. Университетский, 100
vdtitov08@gmail.com

В статье рассматриваются проблемы, риски и этические дилеммы, возникающие при использовании автономных систем на базе искусственного интеллекта акцентом на концепции «разрыва ответственности». По мере того как системы ИИ все больше внедряются в различные отрасли, от правоохранительных органов до здравоохранения, трудности с возложением ответственности за действия этих систем вызывают насущные моральные проблемы. В статье рассматривается, как предвзятость ИИ, непредсказуемость автономного принятия решений и эрозия автономии пользователя могут привести к опасным последствиям. В ней содержится призыв к созданию более строгих нормативных рамок и этических гарантий для обеспечения ответственного применения ИИ в условиях высоких ставок.

Ключевые слова: искусственный интеллект, разрыв ответственности, автономные системы, этические дилеммы, предвзятость в искусственном интеллекте

Введение. За последние десятилетия в области искусственного интеллекта были достигнуты значительные успехи, особенно в разработке автономных систем на основе нейронных сетей. Такие системы, включая самоуправляемые автомобили, автономное оружие, промышленные роботы и управляемые ИИ медицинские и юридические платформы, обещают выполнять задачи с большей скоростью, точностью и надежностью по сравнению с человеческой или традиционной машинной работой. Потенциальные преимущества таких систем – снижение затрат, повышение производительности, улучшение безопасности и облегчение рутинных задач – широко признаны.

Сегодня преобладает мнение, что ИИ не заменит полностью человека, а станет передовым инструментом в его распоряжении [5]. Часто проводятся аналогии с традиционными инструментами: например, художники уподобляют ИИ кисти, а писатели сравнивают переход к ИИ с переходом от чернильных ручек к пишущим машинкам. Однако эти сравнения не позволяют уловить фундаментальную разницу между традиционными инструментами и системами, управляемыми ИИ. Например, кисть – это всего лишь продолжение руки художника, полностью находящееся под его контролем. Нейронные сети, напротив, являются продуктом коллективных человеческих усилий, и полученная система работает как «черный ящик» [1]. Даже ее создатели могут не до конца понимать внутреннюю работу системы, несмотря на возможность наблюдать за ее входами и выходами. Во многом это связано с природой нейронных сетей и других нелинейных моделей машинного обучения, которые опираются на субсимволи-

ческие представления, нелегко поддающиеся интерпретации даже разработчиками и специалистами по изучению данных.

Основная часть. Сложность и непредсказуемость автономных систем, управляемых сложными алгоритмами, поднимает важные вопросы об ответственности. Поскольку ни один человек не может нести полную ответственность за поведение таких систем, ученые ввели понятие «разрыв ответственности» («responsibility gap») [13]. Этот термин обозначает этическую проблему, связанную с возложением моральной ответственности за неблагоприятные результаты, вызванные системами ИИ. В частности, этот вопрос является критически важным в контексте автономного оружия, где неспособность возложить ответственность может иметь серьезные последствия. Многие эксперты утверждают, что существование этого разрыва в ответственности требует осторожности при развертывании автономных систем, особенно тех, которые потенциально могут причинить вред, например, автономного оружия [3,4, 9, 10].

При взаимодействии с интеллектуальными системами – будь то при их производстве, программировании, продаже или использовании – становится сложно определить, в какой степени человек должен нести ответственность за результаты, ставшие следствием действий этих систем. Хотя общепризнанно, что программисты, производители и операторы автономных систем должны проявлять должную осмотрительность, чтобы избежать обвинений в халатности, точный характер этой необходимой осмотрительности остается неоднозначным [11]. Следовательно, неизбежна определенная несправедливость в распределении ответственности, часто называемая «асимметрией ответственности». Будут иметь место как ложноположительные, так и ложноотрицательные результаты, что приведет к сценариям, в которых люди будут либо несправедливо привлечены к ответственности, либо, наоборот, недостаточно подотчетны – примерно как в современных условиях, когда интеллектуальные системы не задействованы.

Проблема особенно актуальна в ситуациях с высокой чувствительностью, поскольку она может иметь ряд негативных последствий для использования интеллектуальных систем. Обнаружить ошибки в таких системах может быть сложно, а пользователи и заинтересованные стороны могут не доверять им или принимать обоснованные решения на основе их рекомендаций. Отсутствие прозрачности обусловлено неспособностью пользователей понять логику, лежащую в основе решений системы, что подрывает доверие и вызывает опасения по поводу самостоятельности тех, кто взаимодействует с этими системами. Существует также опасение, что системы ИИ могут подорвать автономию пользователя – будь то путем тонкого подталкивания или более явного манипулирования, – особенно если поведение систем не поддается простой интерпретации или объяснению [12].

Дискуссии об ответственности часто фокусируются на громких сценариях, таких как наезд на пешехода самоуправляемым автомобилем, однако проблема гораздо более распространенная и непосредственная. Например, такие платформы, как YouTube и «ВКонтакте», используют алгоритмы рекомендаций, учитывающие личные предпочтения пользователей. Системы формируют

выбор пользователя, поднимая вопрос о том, насколько велика доля самостоятельности в принятии решений человеком, в соответствии с аристотелевскими представлениями о добровольности действий. По сути, может показаться, что люди действуют автономно, однако на их выбор все больше влияют – или «программируют» – алгоритмы, лежащие в основе этих систем.

Более того, прозрачность того, как корпорации, от OpenAI до отечественного Сбера, управляют своими нейросетями и алгоритмическими системами, ограничена. Пользователи часто воспринимают результаты работы этих систем как нейтральные и беспристрастные, что потенциально делает их уязвимыми для манипуляций или обмана. Хотя обычно предполагается, что никакого преднамеренного обмана не происходит, отсутствие понимания работы этих систем создает новый уровень риска, это поднимает важные этические вопросы о степени влияния систем ИИ на поведение человека, зачастую без его полного осознания или согласия.

В недавней истории есть несколько примеров, иллюстрирующих, как системы искусственного интеллекта могут отражать и даже усиливать человеческие предубеждения. Одним из ярких примеров является инструмент Amazon для проверки резюме с помощью искусственного интеллекта, который в конечном итоге был отменен после того, как выяснилось, что он систематически отдает предпочтение кандидатам-мужчинам. Такая предвзятость, скорее всего, была вызвана тем, что ИИ обучался на исторических данных, которые состояли преимущественно из резюме кандидатов-мужчин, что усиливало существующий гендерный дисбаланс [8]. Аналогичный тревожный инцидент произошел с системой классификации фотографий ИИ компании Google, которая ошибочно назвала темнокожих людей «гориллами» [BBC, 2015] – грубая ошибка, отражающая глубоко укоренившиеся расистские стереотипы. Более того, исследование Буоламвини и Гебру показало, что системы распознавания лиц особенно неточны при идентификации темнокожих женщин, что подчеркивает, как такие технологии могут непропорционально вредить маргинализированным сообществам. Например, использование правоохранительными органами системы распознавания лиц на основе ИИ может несправедливо нацеливаться на цветных женщин, что может привести к ложной идентификации преступников [7].

Помимо этих примеров, существует опасение, что системы ИИ, хотя и являются якобы нейтральными, могут отклоняться от этого идеала тонким или явным образом. Такие влияния, как рекламные контракты, стремление к предпочтениям аудитории или даже целенаправленные атаки на отдельных людей или учреждения, могут привести к предвзятости. Предполагается, что подобная технология может использоваться спецслужбами для преследования таких фигур, как Эдвард Сноуден или Джулиан Ассанж, демонстрируя потенциал использования ИИ в стратегических или манипулятивных целях. Более того, по мере того как голосовые помощники на базе ИИ, такие как Siri или Алиса, все больше интегрируются в повседневную жизнь, особенно при взаимодействии с детьми, восприятие этих систем как полноценных социальных агентов вызывает этические вопросы о влиянии, которое они оказывают на юные умы.

Хотя эти опасения не обязательно имеют под собой паранойю, они подчеркивают значительные риски, связанные с ИИ. Не так давно концепция «информационной войны» казалась надуманной, но сегодня большинство правительств содержат специальные агентства для борьбы с такими угрозами. В этом меняющемся ландшафте искусственный интеллект стал мощным инструментом, который все чаще внедряется в различные рабочие процессы и процессы принятия решений. Однако стремительное развитие искусственного интеллекта несет в себе и существенные риски, а проблема распределенной ответственности делает его потенциально непредвиденным источником угроз личным и общественным свободам.

Чтобы снизить эти риски, регулирующие органы должны проявлять осторожность при разрешении использования автономных интеллектуальных систем в условиях высоких ставок. Такие системы должны быть спроектированы не просто как преднамеренные агенты, а как моральные агенты, способные принимать этические решения. Кроме того, необходимо создать четкие рамки распределения ответственности, чтобы обеспечить подотчетность и защиту прав человека в условиях растущего влияния ИИ.

Заключение. Таким образом, появление искусственного интеллекта и автономных систем сопряжено со сложными проблемами, рисками и этическими дилеммами, которые нельзя игнорировать. По мере интеграции этих систем в такие критически важные отрасли, как транспорт, правоохранительные органы, здравоохранение и оборона, все более актуальным становится вопрос подотчетности – разрыва ответственности. Непредсказуемость принятия решений ИИ в сочетании с непрозрачностью моделей машинного обучения затрудняет распределение ответственности, когда что-то идет не так. Более того, потенциальная возможность ИИ увековечить или усилить человеческие предубеждения добавляет еще один слой этических проблем, особенно когда эти системы воздействуют на уязвимые группы населения. Устранение разрыва в ответственности требует многогранного подхода. Этические принципы проектирования должны быть заложены в разработку ИИ, чтобы эти системы функционировали как моральные агенты, а не просто операционные инструменты. Необходимо создать четкую нормативную базу для определения ответственности, обеспечения прав человека и защиты людей от непреднамеренного вреда. Кроме того, прозрачность систем ИИ имеет решающее значение для укрепления доверия и обеспечения того, чтобы пользователи и заинтересованные стороны могли понимать и оспаривать решения ИИ. По мере того как развертывание автономных систем продолжает расширяться, политикам, разработчикам и обществу в целом необходимо вплотную заняться решением этих этических проблем. Только устранив пробел в ответственности и обеспечив ответственное и прозрачное использование ИИ, мы сможем в полной мере использовать его потенциал и одновременно снизить риски, которые он несет для индивидуальных свобод, безопасности и общественных ценностей.

Библиографический список

1. Акулин, Е. В. Кибернетика «черного ящика» и искусственный интеллект / Е. В. Акулин, Л. Е. Свиридова // Fundamental and applied approaches to solving scientific problems : Сборник научных статей по материалам VII Международной научно-практической конференции, Уфа, 21 декабря 2021 года. – Уфа: Общество с ограниченной ответственностью "Научно-издательский центр "Вестник науки", 2021. – С. 43-46.
2. Гаспарян Д. Э. Этические дилеммы применения информационных технологий в сфере образования: российский и зарубежный опыт // Вестник Московского государственного университета культуры и искусств. – 2020. – №. 1 (93). – С. 99-110.
3. Глуховский А. С., Дурнев А. Д., Чирва Д. В. Распределенная моральная ответственность в сфере искусственного интеллекта // Этическая мысль. – 2024. – Т. 24. – №. 1. – С. 129-143.
4. Игнатъев А. Г. Этико-философские проблемы проектирования искусственного морально-го агента // Этическая мысль. – 2024. – Т. 24. – №. 1. – С. 87-100.
5. Цвык В. А., Цвык И. В., Цвык Г. И. Искусственный интеллект в современном обществе: шаги, вызовы, стратегии // Вестник Российского университета дружбы народов. Серия: Философия. – 2024. – Т. 28. – №. 2. – С. 589-600.
6. BBC. Google apologises for Photo app's racist blunder // BBC News. – 2015. – 1 July. [Электронный ресурс] – Режим доступа: <https://www.bbc.com/news/technology-33347866> (дата обращения: 07.09.2024).
7. Buolamwini J., Gebru T. Gender shades: intersectional accuracy disparities in commercial gender classification // Proceedings of Machine Learning Research. – 2018. – Т. 81. – P. 1–15.
8. Dastin J. Amazon scraps secret AI recruiting tool that showed bias against women // Reuters. – 2018. – 9 October. [Электронный ресурс] – Режим доступа: <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G> (дата обращения: 07.09.2024).
9. Kiener M. Can we Bridge AI's responsibility gap at Will? // Ethical Theory and Moral Practice. – 2022. – Т. 25. – №. 4. – С. 575-593.
10. Königs P. Artificial intelligence and responsibility gaps: what is the problem? // Ethics and Information Technology. – 2022. – Т. 24. – №. 3. – С. 36.
11. Munch L., Mainz J., Bjerring J. C. The value of responsibility gaps in algorithmic decision-making // Ethics and Information Technology. – 2023. – Т. 25. – №. 1. – С. 21.
12. Oimann A. K. The responsibility gap and LAWS: A critical mapping of the debate // Philosophy & Technology. – 2023. – Т. 36. – №. 1. – С. 3.
13. Santoni de Sio F., Mecacci G. Four responsibility gaps with artificial intelligence: Why they matter and how to address them // Philosophy & Technology. – 2021. – Т. 34. – №. 4. – С. 1057-1084.

ARTIFICIAL INTELLIGENCE AND THE RESPONSIBILITY GAPS: CHALLENGES, RISKS AND ETHICAL DILEMMAS OF AUTONOMOUS SYSTEMS

Vladislav Dmitrievich Titov

Volgograd State University

400062, Russia, Volgograd, 100, Universitetsky Ave.

vdtitov08@gmail.com

The article discusses the problems, risks and ethical dilemmas arising from the use of autonomous AI-based systems with an emphasis on the concept of 'responsibility gap'. As AI systems are increasingly deployed in a variety of industries, from law enforcement to healthcare, the difficulty in assigning responsibility for the actions of these systems raises pressing moral concerns. This article examines how AI bias, the unpredictability of autonomous decision-making, and the erosion of user autonomy can lead to dangerous consequences. It calls for stronger regulatory frameworks and ethical safeguards to ensure responsible use of AI in high stakes environments.

Keywords: artificial intelligence, responsibility gap, autonomous systems, ethical dilemmas, bias in AI

АЛГОРИТМИЧЕСКОЕ ПРАВО КАК ОСНОВА ДЛЯ ВНЕДРЕНИЯ АВТОНОМНЫХ СИСТЕМ ДЛЯ УПРАВЛЕНИЯ КОРПОРАЦИЯМИ

Романова Анна Сергеевна

Московский физико-технический институт (национальный исследовательский университет),
141701, Россия, Московская обл., г. Долгопрудный, ул. Институтский пер., 9
romanova.as@phystech.edu

В докладе предлагаются основы формирования алгоритмического права для внедрения автономных систем искусственного интеллекта при управления корпорациями. Также представлены основные типы автономных систем искусственного интеллекта для корпоративного управления: многофункциональные командные центры, персонифицированные виртуальные системы, и гуманоидные роботы. В ближайшей перспективе ожидается появление гибридных систем на базе объединения многофункциональных цифровых фабрик и персонифицированных виртуальных систем или гуманоидных роботов.

Ключевые слова: искусственный интеллект, корпоративное управление, автономные системы, андройды, вычислительное право, выделенный операционный контекст, алгоритмические решения.

Введение. Начиная с 2014 года компании назначают на управленческие позиции системы искусственного интеллекта (далее ИИ). От функции поддержки принятия решений системы ИИ переходят в режим управления принятием решений. Основными типами систем ИИ, которые уже получили официальные назначения на управляющие позиции в международных компаниях являются: многофункциональные цифровые командные центры (далее ЦКЦ), персонифицированные виртуальные системы, гуманоидные роботы. Предсказуемым этапом в развитии автономных систем ИИ для управления корпорациями является возникновение гибридных систем путем объединения многофункциональных цифровых фабрик и интерфейса в виде персонифицированных виртуальных систем и/или гуманоидных роботов. Топ-менеджеры – физические лица, и топ-менеджеры – автономные системы ИИ должны соблюдать установленные законодательством, уполномоченными регуляторами, и компаниями требования и стандарты корпоративного управления. Ключевым фактором, который влияет на различия в принятии решений между менеджером – человеком и менеджером – системой ИИ, является разница между социальными и техническими системами. Основной целью создания алгоритмического законодательства является создание надежной правовой основы для совместного взаимодействия технических и социальных систем.

Типы и функции автономных систем управления корпорациями.

Возможность использования преимуществ таких технологий, как большие данные, блокчейн, и машинное обучение позволяет внедрять новые опции по борьбе с неэтичным поведением в корпоративном управлении. Основные типы современных автономных систем ИИ для управления корпорациями представлены в табл.

Основные типы автономных систем для управления корпорациями

Многофункциональные цифровые командные центры	Персонализированные виртуальные системы ИИ	Гуманоидные роботы
Цифровой командный центр Panorama [1]	Алисия Т — топ-менеджер шведской компании Tieto [2] VITAL, Spock — ИИ системы гонконгской компании Deep Knowledge Ventures [3] Aiden Insight — наблюдатель без права голоса в совете директоров Международной холдинговой компании (ИНС) со штаб-квартирой в Абу-Даби [4] Tang Yu — CEO китайской компании Fujian NetDragon Websoft [5]	- CEO польской компании Dictador робот Мика [6] - Робот София - посол инноваций в области робототехники Программы развития ООН [7]

Необходимость алгоритмического права. Одной из главных причин необходимости разработки алгоритмического законодательства является невозможность точного перевода формулировок и понятий с естественных языков на формальные. «Хорошо известно, что формальные языки не могут содержать нюансы естественных языков и что процедуры закона, обеспечивающие защиту, предоставляемую законом, коренятся в использовании естественного языка» [8].

По мнению многих ученых «правовая автоматизация всегда будет компромиссом между (идеализированными) преимуществами автоматизации и эрозией юридических процедур» [8]. Концепция закона как вычисления (иногда называемая «вычислительным законом») направлена на то, чтобы свести закон к набору алгоритмов, которые могут автоматически выполняться на компьютере, плавно преобразуя необработанные входные данные в юридические выводы [9].

Основы алгоритмического права. В настоящее время существует точка зрения, что топ-менеджеры – автономные системы ИИ, свободные от человеческих предубеждений и эмоций, обладают способностью последовательно поддерживать этические стандарты, поощряя этическое и социально ответственное поведение на рабочем месте [10]. Однако для автономных систем ИИ недостаточно указать необходимость соблюдать принципы справедливости, конкурентоспособности, и прозрачности; необходимо определить, как математически рассчитать справедливость, конкурентоспособность и прозрачность, и в каких числовых пределах справедливость все еще будет справедливой, а в каких пределах она уже справедливой не будет.

Принятие современных алгоритмических решений основано прежде всего на теории вероятностей, центральных предельных теоремах, и законе больших чисел. Согласованное использование теории вероятностей имеет принципиальное значение при конструировании алгоритмических решений – оно вводит понятие неоднозначности принимаемого решения.

Структурирование общества в эпоху алгоритмических решений.

Ученый-правовед и философ Дебора Хеллман говорит о том, что алгоритмические термины имеют значение не просто для теории машинного обучения, а оказывают влияние на структурирование общества в эпоху алгоритмических решений [11]. Появление больших данных вместе с машинным обучением, вероятно, приведет к существенному увеличению влияния прошлого на будущее, поскольку анализ на основе данных по своей сути основан на прошлом [11]. Хеллман отстаивает «принцип противодействия усугублению предыдущей несправедливости» [11], который позволяет понять, когда и почему некоторые данные и алгоритмические решения допустимы, а некоторые нет. Таким образом, качественное алгоритмическое законодательство должно оказать значительное влияние на долгосрочные перспективы развития человеческой цивилизации в целом.

Принятие решений неуполномоченными лицами. Программистам приходится разрабатывать функции стоимости – алгоритмы, которые назначают и рассчитывают ожидаемые затраты различных возможных вариантов, выбирая тот, который имеет наименьшие затраты, – которые в экстремальных случаях потенциально определяют, кто будет жить, а кому предстоит умереть [12]. Что же произойдет, если у компании нет возможности легитимно не сформулировать, какие именно методы определения алгоритмической справедливости, конкурентоспособности, и прозрачности она выбрала? Тогда можно будет говорить о том, что управлением компанией занимаются неуполномоченные лица (разработчики, программисты и т.д.).

Модель разработки и внедрения автономных систем ИИ для управления корпорациями. Следует отметить, что в настоящее время ни в одной стране мира нет законодательства, устанавливающего правила работы автономных систем ИИ в корпоративном управлении. Разработка такого законодательства, основанного на алгоритмическом праве, является предпосылкой успешного внедрения автономных систем искусственного интеллекта для целей корпоративного управления. Предлагаемая модель разработки и внедрения автономных систем искусственного интеллекта (рис.) основана на синтезе вычислительного права, выделенного операционного контекста [13], контролируемой генерации синтетических данных, и алгоритмов машинного обучения.



Рис. Модель разработки и внедрения автономных систем ИИ для советов директоров

Программный код текущего эксперимента представлен в репозитории: <https://github.com/iboard-project>.

Заключение. Развитие корпоративных автономных систем в настоящий момент происходит в условиях отсутствия четкого законодательства. Компании меняют сложившиеся управленческие роли используя доступные им средства, самым популярным из которых являются дисклеймеры. Однако, как показали многочисленные судебные разбирательства по поводу ответственности производителя [14] – перекладывание ответственности на третьих лиц может привести к значительным финансовым последствиям.

Библиографический список

1. ADNOC, ADNOC Wins Industry Technology Award for its Panorama Digital Command Center // [Электронный ресурс]. – URL: <https://adnoc.ae/news-and-media/press-releases/2021/adnoc-wins-industry-technology-award-for-its-panorama-digital-command-center> (дата обращения 11.07.2024).
2. Businesswire. Tieto the First Nordic Company to Appoint Artificial Intelligence to the Leadership Team of the New Data-Driven Businesses Unit // [Электронный ресурс]. – URL: <https://www.businesswire.com/news/home/20161016005092/en/Tieto-the-First-Nordic-Company-to-Appoint-Artificial-Intelligence-to-the-Leadership-Team-of-the-New-Data-Driven-Businesses-Unit> (дата обращения 11.07.2024).
3. Deep Knowledge Ventures // [Электронный ресурс]. – URL: <https://deepknowledgeventures.com/> (дата обращения 11.07.2024).
4. IHC. IHC's Aiden Insight sets a new benchmark for the integration of artificial intelligence in high-level corporate strategy // [Электронный ресурс]. – URL: https://www.ihcuae.com/photo/plugin/article/2024/1715086662_file_1.pdf (дата обращения 11.07.2024).
5. NetDragon. NetDragon's AI Leader Tang Yu Named China's Best Virtual Employee of 2024, 2024. <https://www.netdragon.com/content/2024-04-28/20240428231345555.shtml>.
6. Business Standard. Mika becomes world's first robot CEO, thinks she's better than Musk // [Электронный ресурс]. – URL: https://www.business-standard.com/world-news/mika-becomes-world-s-first-robot-ceo-thinks-she-s-better-than-musk-123110901563_1.htm (дата обращения 11.07.2024).
7. Hanson Robotics // [Электронный ресурс]. – URL: <https://www.hansonrobotics.com/sophia/> (дата обращения 11.07.2024).
8. Meessen P. N. On Normative Arrows and Comparing Tax Automation Systems // Proceedings of the Nineteenth International Conference on Artificial Intelligence and Law. – 2023. – URL: <https://dl.acm.org/doi/10.1145/3594536.3595160> (дата обращения 11.07.2024).
9. Livermore M. A. Rule by rules // Computational Legal Studies: The Promise and Challenge of Data-Driven Research. – Cheltenham (UK): Edward Elgar Publishing, 2020. P. 238–264
10. Skubis I., Wodarski K. Humanoid Robots in Managerial Positions – Decision-making Process and Human Oversight // Scientific Papers of Silesian University of Technology. Organization & Management/Zeszyty Naukowe Politechniki Slaskiej. Seria Organizacji i Zarzadzanie, 2023 Dec 28(189).
11. Hellman D. Sex, Causation, and Algorithms: Equal Protection in the Age of Machine Learning // Discrimination, 2020). n. pag.
12. Lin P. Why ethics matters for autonomous cars // Autonomes Fahren: Technische, rechtliche und gesellschaftliche Aspekte. – Berlin: Springer Nature, 2015. P. 69–85.
13. Romanova A. Elements Of Legislation For Artificial Intelligence Systems // International Journal on Soft Computing, Artificial Intelligence and Applications (IJSCAI), 2024. Vol.13.
14. Cain KG. The McDonald's coffee lawsuit // Journal of Consumer & Commercial Law. 2007. 11(1):14-9.

ALGORITHMIC LAW AS A BASIS FOR THE IMPLEMENTATION OF AUTONOMOUS SYSTEMS FOR CORPORATION MANAGEMENT

Anna S. Romanova

Moscow Institute of Physics and Technology (National Research University),
Institutskiy per., 9, Dolgoprudny, Moscow Region, Russia, 141701
romanova.as@phystech.edu

The article presents foundations of algorithmic law for autonomous artificial intelligence systems in corporate management. It also describes the main types of autonomous artificial intelligence systems for corporate management: multifunctional command centres, personalised virtual systems, and humanoid robots. In the near future, hybrid systems based on the combination of multifunctional digital factories and personalised virtual systems or humanoid robots are expected to emerge.

Keywords: artificial intelligence, corporate governance, autonomous systems, androids, computational law, dedicated operational context, algorithmic decisions.

УДК 004.032.26

МОДЕЛЬ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ СИСТЕМОЙ ЦЕННОСТНЫХ ЧАСТНОСТЕЙ АКТОРА СОЦИОКУЛЬТУРНОГО ПРОСТРАНСТВА

Песецкая Татьяна Ивановна

Белорусский государственный университет культуры и искусств,
220007, Беларусь, Минск, ул. Рабкоровская, 17
tt.psts@gmail.com

В статье представлено описание модели интеллектуального управления системой ценностных частныхостей актора социокультурного пространства. Предложены подходы теории оптимального управления моделирования регуляции аксиологического содержания социокультурного пространства, а именно использование управления типа обратной связи для генерации управляющих воздействий в режиме реального времени с целью достижения определённого уровня значимости тех либо иных ценностей.

Ключевые слова: интеллектуальное управление, динамические систем управления с неопределенностью, регулирование аксиологического содержания социокультурного пространства.

Введение. Пул вызовов в разработке и развитии искусственного интеллекта сегодня касается задач обработки и анализа данных, порождаемых феноменами социокультурных пространств. Следуя концепции социокультурного пространства, представленной доктором философских наук Е.Ю. Шакировой [1], в контексте настоящего доклада с целью дальнейшего моделирования определим социокультурное пространство как многоуровневый, многоэтапный и разноплановый синтез феноменов деятельности и взаимодействий социокуль-

турных акторов (как единичных, так и коллективных), результирующий наполнение пространства характерным действующим акторам содержанием, таким как смыслы, идеи, убеждения, традиции, ценности, знаковые формы, символы, системы аксио-семантических координат. Несомненно, для математического моделирования социокультурных феноменов, которые описываются с помощью концептуально-качественных характеристик необходимы подходы к формированию количественных измерений социокультурного объекта управления, дающих возможности иерархизации и типологизации явлений, проистекающих в социуме, и пригодных для построения математических моделей. Ряд подходов к преобразования качественных характеристик в количественные измерения социокультурного пространства были предложены такими исследователями как Герхард Хофстеде [2], Альфонс Тромпенаарс [3]. Как отмечает Е.Ю. Шакирова: «Развитие его /социокультурного пространства /представляет собой изменение состояний при условии сохранения некоего исходного состояния, порождающего новые состояния. Под влиянием таких процессов как глобализация и нарастание сетевых взаимодействий конфигурация пространства изменяется. Размытость границ, неопределенность, переходность позиций, смена значений аксиологических знаков, трансформация сущностных характеристик – таково социокультурное пространство современности.» [1]. Из данного рассуждения становится очевидно, что при моделировании явлений социокультурного пространства важную роль играет смена его состояний, что с точки зрения математического моделирования можно интерпретировать как состояние динамической системы, задаваемой совокупностью дифференциальных уравнений; а также высокая степень неопределённости, обусловленная «размытостью границ» или математически неучтенными факторами моделирования.

Цель данной работы – изложить концепцию модели интеллектуального управления системой ценностных частных актора социокультурного пространства, где под ценностными частными мы понимаем совокупность мыслей, смыслов, идей актора, формирующих содержательное наполнение пространства, определяющее его ценностный базис. Таким образом мы приходим к возможности использования моделей динамических систем управления с неопределенностью для регулирования процессов формирования ценностного содержания социокультурного пространства. Сразу отметим, что ставшие уже классическими модели социальных процессов основаны на формализации объекта управления в виде нелинейной системы дифференциальных уравнений с неопределённостью [4], как правило заданной стохастически. В данной работе мы предложим подходы, основанные на качественной теории оптимального управления, разработанные в рамках исследований белорусской научной школы по оптимизации и оптимальному управлению, созданной докторами математических наук Р.Ф. Габасовым и Ф.М. Кирилловой [5].

Социокультурные измерения как базис моделирования динамических состояний актора социокультурного пространства. Определим, что социокультурное измерение – это количественный показатель качественной характеристики, выражающей контекст того либо иного социокультурного феномена.

Современные технологии построения социокультурных измерений базируются на масштабных опросах, таких, как, например, World Values Survey [6], где ответы переводятся в числовые эквиваленты с разной вариативностью шкал. Динамические модели имеют дело с кусочно-непрерывными функциями, тогда как в опросах мы имеем дело с дискретными величинами. В работе с опросами для отражения динамики можно использовать сложные измерения, базирующиеся на суперпозиции базовых измерений с весовыми значениями, например:

$$X(t) = \sum_{i \in I} p_i(t) x_i(t),$$

где x_i – базовые дискретные измерения, p_i – веса; или более сложный вариант

$$X(t) = F(x_i, i \in I).$$

Если же мы переходим к моделированию социокультурных измерений, для их построения и анализа системами искусственного интеллекта, снимается вопрос трудоемкости вычислений и могут вводиться изначально непрерывные функции измерений, например интенсивность упоминания в сообщениях социальной сети, что «семья – это ценность» в некоторой социальной группе (где самое простое – отношение количества упоминаний к количеству публикаций). Однако, когда мы глубже погружаемся в проблему моделирования социокультурного измерения, отражающего аксиологические феномены социокультурного пространства, мы сталкиваемся с вопросом построения релевантной модели измерений, отражающих различные уровни значимости той либо иной ценности, сформированной акторами социокультурного пространства. Один из подходов к такого рода моделированию был нами предложен в [7], где за основу берется иерархизации присущих человеку генерируемых продуктов когнитивной детальности, называемых частностями [8], из которых для примера мы даём определение восьми, чтобы продемонстрировать уровни интенсификации ценностного ориентира актора (табл.).

Таблица

Ценностные частности актора социокультурного пространства

Частность	Описание ценностной частности
Движение x_1	Я выражаю положительное/негативное отношение к этой ценности с определенной шкалой значимости, двигаясь в ее контексте, но не определяя ее влияния на мою жизнь.
Ощущение x_2	Первично определяю влияние положительное/отрицательное данного ценностного ориентира с определенной шкалой значимости на мою жизнь, пассивно реагируя на него.
Чувство x_3	Реагирую (высказываюсь, даю отклик во внешний социум) положительно/ отрицательно с определенной шкалой значимости на данный ценностный ориентир в рефлексировании его влияния на жизнь.
Мысль x_4	Размышляю положительно/отрицательно об данном ценностном ориентире, анализирую его влияние на свою жизнь и окружающий социум, придавая ему значение с определенной шкалой значимости.

Частность	Описание ценностной частности
Смысл x_5	Вижу, распознаю, определяю положительно/отрицательно причинно-следственные связи воздействия данного ценностного ориентира на мою жизнь и окружающий социум, придавая ему значение с определенной шкалой значимости. Здесь начинается осознанная включенность актора в разрешение социумных противоречий, вызванных данным ценностным ориентиром.
Суть x_6	Понимаю императивность воздействия данного ценностного ориентира на мою жизнь и окружающий социум, давая ему положительную/отрицательную оценку с определенной шкалой значимости, убедительно отстаиваю свою точку зрения в социуме, могу применить императивность данной ценности к решению как личных задач, так и задач, стоящих перед определенными группами.
Идея x_7	Различаю законы действия данного ценностного ориентира на мою жизнь и окружающий социум, давая ему положительную/отрицательную оценку с определенной шкалой значимости, могу и готов действовать в направлении укрепления либо нивелирования данного ценностного императива в социуме, являясь вдохновителем той либо иной группы в достижении поставленной мною цели.
Право x_8	Знаю механизмы ценностного ориентира, запускающий его управляющие специфики в социуме, умею оперировать ими в той либо иной социумной группе, для достижения целей.

Под интенсификацией ценностного ориентира частностями будем понимать насыщенность каждого суждения актора социокультурного пространства частностями движений, ощущений, чувств, мыслей, смыслов, сути, идей, прав в глубине распознавания данного ценностного ориентира и умении оперировать этими частностями для достижения целей. Например, частности ценности «патриотизм» от мысли «детям необходимо прививать патриотизм» до сути «я готов защищать свою родину с оружием в руках» [9].

Таким образом для реализации модели интеллектуального управления ценностными частностями актора социокультурного пространства, на первом этапе необходимо построить измерения: 1) распознать в тексте(речи) наличия высказываний об определенной ценности; 2) классифицировать высказывания по n -частностям; 3) определить числовые значения интенсивности частностного высказывания x_i по установленной шкале. Для обучения нейронной сети необходимо создать частностные классы высказываний с присвоением каждому высказыванию числового маркера его интенсивности, учитывая моделирование маркера как значения непрерывной по времени функции на промежутке управления T : $x_i(t) = f(t), t = T, i \in I$. В более усложнённой модели в измерении потребуются так же учитывать частоту обращения актора к теме исследуемых ценностей.

Отметим, что система иерархизации частностей будет усложняться по мере развития когнитивных моделей, где одной из вершинных характеристик

частотной разработанности актора является его осознанное влияние на условия развития окружающего социокультурного пространства [8].

Динамическая модель системы управления ценностными частностями актора социокультурного пространства. В терминах теории оптимального управления сформулируем задачу регулирования изменения n ценностных частностей (характеризующих некоторую ценность) актора социокультурного пространства $x(t) = (x_i(t), i \in I)$ на промежутке времени $T = [t_*, t^*]$:

$$\dot{x}(t) = Ax(t) + u(t) + w(t), t \in T \quad (1)$$

где $A - n \times n$ матрица, отражающая влияние одних ценностных частностей на другие, так, например интенсивность чувств стимулирует выработку мысли, определённая насыщенность мыслями приводит к рождению смыслов и т.д. Матрица A с постоянными коэффициентами, является простейшей моделью и отражает моделирование изменения частностей с помощью постоянных весов:

$$\dot{x}_i(t) = \sum_{j=\overline{1,n}} a_{ij} x_j(t)$$

С целью регулирования системы (1) на нее действует ограниченное управление:

$$u(t) \in U = \{u(t) \in R^m, u_{*j} \leq u_j(t) \leq u_j^*, j = \overline{1,n}, t \in T\},$$

которое в терминальный момент времени t^* должно гарантировать принадлежность терминального состояния системы заданному множеству X^*

$$x(t^*) \in X^* = \{x \in R^n, \bar{g}_{*i} \leq x_i \leq \bar{g}_i^*\}$$

при действующих на систему ограниченных возмущениях:

$$w(t) \in W = \{w(t) \in R^n, w_{*i} \leq w_i(t) \leq w_i^*, i = \overline{1,n}, t \in T\},$$

обеспечив минимальную затрату управляющих ресурсов:

$$\varphi(t^*) = \int_{t_*}^{t^*} b' u(t) dt \rightarrow \min, b \in R^n$$

Учитывая тот факт, что измерения частностей $x_i(t)$ ограничены минимальным и максимальным значениями шкалы:

$$x(t) \in X = \{x(t) \in R^n, g_* \leq Hx \leq g^*, t \in [t_*, t^*]\},$$

получаем линейную терминальную задачу оптимального управления недетерминированной динамической системой:

$$\varphi(t^*) = \int_{t_*}^{t^*} b' u(t) dt \rightarrow \min, b \in R^n, \quad (2)$$

$$\dot{x}(t) = Ax(t) + u(t) + w(t), t \in T \quad (3)$$

$$x(t) \in X = \{x(t) \in R^n, g_* \leq Hx \leq g^*, t \in [t_*, t^*]\} \quad (4)$$

$$u(t) \in U = \{u(t) \in R^m, u_{*j} \leq u_j(t) \leq u_j^*, j = \overline{1,n}, t \in T\} \quad (5)$$

$$w(t) \in W = \{w(t) \in R^n, w_{*i} \leq w_i(t) \leq w_i^*, i = \overline{1,n}, t \in T\} \quad (6)$$

$$x(t^*) \in X^* = \{x \in R^n, \bar{g}_{*i} \leq x_i \leq \bar{g}_i^*\} \quad (7)$$




Рис. Модель интеллектуального управления системой ценностных частных актора социокультурного пространства

Поскольку построить явное решение задачи (2) – (7), то есть оптимальное управление $u^0(t) \in U$ для системы (3) не представляется возможным, задача (2) – (7) погружается в класс задач генерации оптимального управления в дискретные моменты времени:

$$t \in [t_* + kh, t_* + (k + 1)h], k = \overline{0, N - 1}, h = (t^* - t_*)/N,$$

в которые измерительному устройству (например, нейронной сети, анализирующей интернет-пространство) доступны измерения состояний системы:

$$x(t_* + kh), k = \overline{0, N - 1}.$$

Таким образом мы получаем модель интеллектуального управления с измерительным устройством и регулятором (рис.), работающую по принципу обратной связи и генерирующую дискретную управляющую последовательность в реальном времени:

$$u(t_* + kh), k = \overline{0, N - 1}.$$

Математические подходы к решению задач подобных задаче (2) – (7) представлены в [10]. С результатами симуляций для простейшей, одномерной модели регулирования ценностных ориентиров актора социокультурного пространства, не учитывающий частностные характеристики, образующие ценность можно ознакомиться в [7].

Заключение. В результате исследования построена модель интеллектуального управления системой ценностных частных актора социокультурного пространства, состоящая из измерительного устройства типа нейронной сети, устанавливающей значения измерений частных актора в некоторые дискретные промежутки времени, и регулятора, вырабатывающего в реальном времени на основе этих измерений управляющий сигнал по типу обратной связи.

В перспективе в продолжении данного исследования планируется осуществить симуляцию модели, работающую с массивами баз социокультурных

данных, полученных в результате опросов и доступных в интернет-пространстве, таких, например, как World Values survey.

Библиографический список

1. Шакирова Е. Ю. Социокультурное пространство современности: основные характеристики // Культура. Духовность. Общество. 2013. №7. С.174-180.
2. Hofstede, G. and Hofstede, G.J. and Minkov, M. Cultures and Organizations: Software of the Mind, Third Edition. New York: McGraw Hill LLC, 2010. – 576 p.
3. Trompenaars, F. Hampden-Turner Ch. Riding the waves of culture. London: Nicholas Brealey Publishing, 1998. – 260 p.
4. Comissiong, D.M.G., Sooknanan, J. A review of the use of optimal control in social model // International Journal of Dynamic and Control. – 2018. – № 6. – P. 780-787.
5. Альсевич В.В., Дмитрук Н.М., Калинин, А.И. Рафаил Габасов: 80 лет : библиографический указатель. Минск: Издательский центр БГУ, 2015. – 72 с.
6. Worldvaluessurvey.org – World Values Survey [Электронный ресурс]. Режим доступа: <https://www.worldvaluessurvey.org>
7. Pesetskaya, T. Real-Time Feedback Control Models for Regulating Values Development of the Social Actors. 2023. International Conference on Electrical, Communication and Computer Engineering (ICECCE). Dubai, United Arab Emirates. 6 pages. [Электронный ресурс]. Режим доступа: doi: 10.1109/ICECCE61019.2023.10442426.
8. Сердюк, В. Парадигма. Т. 2: Парадигма Человека. Москва: Ленанд, 2022. – 985 с.
9. Кислач, А. О. Песецкая, Т. И. Патриотизм в системе современных ценностей // Культура. Наука. Творчество : XV Международная научно-практическая конференция : сборник научных статей. Минск: БГУКИ, 2021. С. 132-138.
10. Габасов Р.Ф., Кириллова Ф.М., Песецкая Т.И. Реализация в реальном времени оптимальных обратных связей по выходу для линейных систем в условиях неопределенности. // Известия РАН. Теория и системы управления. –2005. – №4. – С. 44 – 56.

MODEL OF INTELLIGENT CONTROL OF SOCIOCULTURAL ENVIRONMENT ACTOR VALUE PARTICULARS SYSTEM

Pesetskaya Tatyana Ivanovna

Belarusian State University of Culture and Arts,
Rabkorovskaya st.,17, Minsk, Belarus, 220007
tt.psts@gmail.com

The article presents a description of the model of intelligent control of the system of value particulars of the actor of the socio-cultural environment. The approaches of the theory of optimal control for modeling the regulation of the axiological content of the socio-cultural environment are proposed. The use of feedback control to generate control signals in real time in order to achieve a certain level of significance of value particulars is discussed.

Keywords: intelligent control, dynamic control systems with uncertainty, regulation of the axiological content of the sociocultural environment.

ПОЯВЛЕНИЕ ПОСТЛЮДЕЙ И КИБОРГОВ: СТИРАНИЕ ГРАНИЦ МЕЖДУ ЛЮДЬМИ И МАШИНАМИ

Сметана Владимир Васильевич

АНО НИИ «Цифровой интеллект», Москва, Россия.

smetanavv@mail.ru

Настоящая научная статья посвящена философскому исследованию феномена появления постлюдей и киборгов, а также этическим и социальным последствиям стирания границ между человеком и машиной. В работе анализируются ключевые технологические тенденции, такие как развитие нейроинтерфейсов, искусственных органов, цифрового сознания и искусственного интеллекта, которые способствуют глубокой интеграции человека с технологиями и появлению новых форм разумных существ.

Ключевые слова: постчеловек, киборг, трансгуманизм, искусственный интеллект (ИИ), цифровое сознание, загрузка сознания, нейроинтерфейсы, этика технологий, философия сознания, будущее человечества.

Интеграция с технологиями.

1. Нейроинтерфейсы и их влияние на взаимодействие человека и машины

Нейроинтерфейсы, устройства, обеспечивающие прямой обмен информацией между мозгом и компьютером, представляют собой одну из наиболее перспективных и одновременно спорных областей технологического развития. С одной стороны, они открывают беспрецедентные возможности для лечения неврологических заболеваний, восстановления утраченных функций и расширения когнитивных способностей человека. С другой стороны, они поднимают ряд сложных этических и философских вопросов, связанных с природой сознания, идентичности и свободой воли.

Влияние нейроинтерфейсов на взаимодействие человека и машины может быть рассмотрено в нескольких аспектах:

- **Когнитивное расширение:** Нейроинтерфейсы могут позволить человеку получать информацию непосредственно из цифровых источников, управлять компьютерами и другими устройствами силой мысли, а также улучшать память, внимание и другие когнитивные функции [1]. Это поднимает вопросы о том, что значит быть человеком в эпоху, когда границы между биологическим и искусственным разумом становятся все более размытыми.

- **Лечение и реабилитация:** Нейроинтерфейсы уже используются для восстановления двигательных функций у пациентов с параличом, а также для лечения эпилепсии, болезни Паркинсона и других неврологических заболеваний. В будущем они могут стать ключевым инструментом для борьбы с деменцией, депрессией и другими психическими расстройствами. Однако, использование нейроинтерфейсов для медицинских целей также поднимает этические вопросы, связанные с возможными побочными эффектами, неравенством в доступе к технологиям и изменением самовосприятия пациентов.

- **Социальное взаимодействие:** Нейроинтерфейсы могут изменить способы коммуникации и взаимодействия людей друг с другом. Например, они могут позволить обмениваться мыслями и эмоциями напрямую, без использования слов, или создавать новые формы коллективного интеллекта. Однако, это также может привести к появлению новых форм социального контроля и манипуляции, а также к усилению цифрового неравенства.

2. Искусственные органы и протезы: расширение физических возможностей

Развитие искусственных органов и протезов также способствует стиранию границ между человеком и машиной. Современные протезы уже позволяют людям с ограниченными возможностями вести активный образ жизни, а в будущем они могут превзойти по функциональности естественные органы. Это открывает перспективы для радикального расширения физических возможностей человека, но также поднимает вопросы о том, что значит быть человеком в эпоху, когда тело становится все более модифицируемым и улучшаемым [2].

Философские аспекты развития искусственных органов и протезов включают:

- **Изменение понятия нормы:** Традиционное представление о нормальном человеческом теле может быть пересмотрено в свете возможности его технологического улучшения. Это может привести к изменению социальных норм и ценностей, а также к появлению новых форм дискриминации и стигматизации.

- **Идентичность и самовосприятие:** Использование искусственных органов и протезов может повлиять на самовосприятие человека и его идентичность. Это особенно актуально в случае нейропротезов, которые могут влиять на когнитивные функции и личность.

- **Справедливость и доступность:** Высокая стоимость искусственных органов и протезов может привести к усилению социального неравенства. Необходимо обеспечить справедливый доступ к этим технологиям для всех, кто в них нуждается.

3. Трансгуманизм и его философские основы

Трансгуманизм – это философское и социальное движение, которое выступает за использование науки и технологий для преодоления биологических ограничений человека и достижения постчеловеческого состояния. Трансгуманисты считают, что человек имеет право на самосовершенствование и что технологии могут помочь ему достичь более высокого уровня развития [3].

Философские основы трансгуманизма включают:

- **Либеральный индивидуализм:** Трансгуманисты подчеркивают важность индивидуальной свободы и права человека на самоопределение, включая право на модификацию своего тела и сознания.

- **Технологический оптимизм:** Трансгуманисты верят в прогресс и считают, что наука и технологии могут решить многие проблемы человечества, включая старение, болезни и страдания.

- Утилитаризм: Трансгуманисты стремятся к максимизации благополучия и счастья для всех существ, и считают, что технологии могут помочь достичь этой цели.

Трансгуманизм вызывает множество споров и критики. Некоторые опасаются, что развитие трансгуманистических технологий приведет к усилению социального неравенства, потере человеческой идентичности и появлению новых форм дискриминации. Другие критикуют трансгуманизм за его технооптимизм и игнорирование потенциальных рисков и негативных последствий развития технологий.

В целом, интеграция человека с технологиями представляет собой сложный и многогранный процесс, который имеет глубокие философские и социальные последствия. Нейроинтерфейсы, искусственные органы и протезы, а также трансгуманистические идеи меняют наше представление о том, что значит быть человеком, и ставят перед нами новые этические и философские вызовы.

Цифровое сознание.

1. Загрузка сознания: теоретические возможности и проблемы

Загрузка сознания (minduploading) представляет собой гипотетическую процедуру переноса сознания человека из биологического мозга в цифровую среду, например, в компьютер или сеть [4]. Эта идея вызывает огромный интерес и споры в философии, нейронауке и футурологии, поскольку она затрагивает фундаментальные вопросы о природе сознания, идентичности и бессмертия.

Теоретически, загрузка сознания может быть осуществлена путем сканирования мозга с высоким разрешением и создания его цифровой копии, которая затем будет запущена на мощном компьютере. Эта цифровая копия, предположительно, будет обладать всеми воспоминаниями, личностью и субъективным опытом оригинального человека.

Однако, на пути к реализации загрузки сознания стоит ряд серьезных проблем:

- Техническая сложность: Современные технологии сканирования мозга далеки от того, чтобы обеспечить достаточную точность для создания полной копии мозга. Кроме того, мы до сих пор не до конца понимаем, как именно мозг порождает сознание, что затрудняет создание его адекватной цифровой модели.

- Философские проблемы: Даже если технические проблемы будут решены, остается вопрос о том, будет ли цифровая копия действительно обладать сознанием и идентичностью оригинального человека. Некоторые философы считают, что сознание неразрывно связано с биологическим телом и не может быть перенесено в цифровую среду. Другие утверждают, что сознание – это информационный процесс, который может быть реализован на разных носителях, включая компьютеры.

- Этические проблемы: Загрузка сознания поднимает ряд этических вопросов, связанных с созданием цифровых копий людей, их правами и обязанностями, а также с возможностью бессмертия в цифровой форме. Например, кто будет владеть цифровой копией сознания? Будет ли она иметь те же права,

что и биологический человек? Как предотвратить злоупотребление этой технологией?

2. Цифровая идентичность и существование в виртуальной реальности

Развитие виртуальной реальности (VR) и дополненной реальности (AR) создает новые возможности для существования и взаимодействия в цифровом пространстве. Люди все больше времени проводят в виртуальных мирах, создавая аватары, общаясь с другими пользователями и участвуя в различных активностях. Это поднимает вопросы о том, как формируется цифровая идентичность, какое значение имеет существование в виртуальной реальности и как оно влияет на нашу жизнь в физическом мире [5].

Философские аспекты цифровой идентичности и существования в VR включают:

- Множественность идентичностей: в виртуальной реальности люди могут создавать и использовать множество аватаров, каждый из которых может представлять разные аспекты их личности или даже совершенно новые идентичности. Это ставит под вопрос традиционное представление о единой и стабильной личности.

- Границы между реальным и виртуальным: с развитием VR и AR границы между реальным и виртуальным миром становятся все более размытыми. Люди могут испытывать сильные эмоции и формировать глубокие отношения в виртуальной реальности, что поднимает вопросы о том, насколько «реальным» является опыт в цифровом пространстве.

- Этика и ответственность: в виртуальной реальности люди могут совершать действия, которые были бы невозможны или неприемлемы в физическом мире. Это поднимает вопросы об этике и ответственности в цифровом пространстве, а также о том, как регулировать поведение пользователей в VR.

3. Философские вопросы о природе сознания и его связи с телом

Проблема сознания является одной из центральных в философии и науке. Несмотря на многочисленные исследования, мы до сих пор не до конца понимаем, как именно мозг порождает субъективный опыт, Квалиа (qualia), самосознание и другие аспекты сознания [6].

Развитие технологий, связанных с цифровым сознанием, таких как загрузка сознания и виртуальная реальность, ставит перед нами новые философские вопросы о природе сознания и его связи с телом:

- Материализм и дуализм: Материалисты считают, что сознание является продуктом мозга и не может существовать отдельно от него. Дуалисты, напротив, утверждают, что сознание – это независимая субстанция, которая может существовать отдельно от тела. Загрузка сознания и существование в виртуальной реальности бросают вызов материалистическому взгляду, поскольку они предполагают возможность существования сознания вне биологического тела.

- Функционализм и воплощенное сознание: функционалисты считают, что сознание определяется функциональной организацией системы, независимо от ее физической реализации. Сторонники теории воплощенного сознания утверждают, что сознание неразрывно связано с телом и его взаимодействием с окружающей средой. Развитие цифрового сознания и VR может помочь про-

лить свет на этот спор, показав, возможно ли создать сознание в системе, которая радикально отличается от биологического мозга.

- Проблема Квалиа (qualia): Квалиа- это субъективные качества опыта, такие как ощущение красного цвета или вкуса шоколада. Одна из главных загадок сознания заключается в том, как объяснить Квалиа в рамках материалистической картины мира. Возможно, развитие цифрового сознания и VR позволит нам лучше понять природу Квалиа и их связь с физическими процессами в мозге или компьютере.

Таким образом, цифровое сознание представляет собой одну из наиболее захватывающих и одновременно сложных областей исследования в современной философии. Развитие технологий, таких как загрузка сознания и виртуальная реальность, ставит перед нами новые вопросы о природе сознания, идентичности и реальности, которые требуют глубокого философского анализа и осмысления.

Искусственный интеллект (ИИ).

1. Сильный ИИ и его потенциал для создания разумных машин

Искусственный интеллект (ИИ) – это область компьютерных наук, занимающаяся созданием систем, способных выполнять задачи, которые обычно требуют человеческого интеллекта, такие как обучение, рассуждение, решение проблем, восприятие и понимание языка. В философии ИИ вызывает особый интерес концепция сильного ИИ, или общего искусственного интеллекта, который обладает способностью понимать или учиться любой интеллектуальной задаче, которую может выполнить человек.

Потенциал сильного ИИ для создания разумных машин огромен и вызывает как надежды, так и опасения. С одной стороны, разумные машины могут стать нашими партнерами в решении глобальных проблем, таких как изменение климата, болезни и бедность. Они могут превзойти нас в научных открытиях, творчестве и других областях, открывая новые горизонты для человечества.

С другой стороны, создание сильного ИИ поднимает ряд серьезных вопросов:

- Контроль: Сможем ли мы контролировать разумные машины, если они превзойдут нас по интеллекту? Что произойдет, если их цели войдут в противоречие с нашими?

- Безопасность: Как обеспечить безопасность сильного ИИ и предотвратить его использование во вред человечеству?

- Этика: Какие этические принципы должны лежать в основе создания и использования разумных машин? Как мы будем относиться к ним, если они обретут сознание?

2. Тест Тьюринга и проблема определения сознания у ИИ

Тест Тьюринга, предложенный Аланом Тьюрингом в 1950 году, является одним из наиболее известных способов определения, может ли машина мыслить. В этом тесте человек-судья общается с двумя собеседниками, один из которых – человек, а другой – машина. Если судья не может определить, кто из них машина, то машина считается прошедшей тест.

Однако, тест Тьюринга вызывает критику со стороны философов и ученых. Некоторые утверждают, что он проверяет только способность машины имитировать человеческое поведение, но не наличие у нее сознания или понимания [7]. Другие указывают на то, что тест Тьюринга может быть пройден машиной, использующей простые алгоритмы и базы данных, без какого-либо реального интеллекта.

Проблема определения сознания у ИИ остается открытой. Мы до сих пор не имеем четких критериев для определения, обладает ли машина сознанием, субъективным опытом и самосознанием. Это затрудняет оценку потенциальных рисков и возможностей, связанных с созданием сильного ИИ.

3. Этические вопросы взаимодействия человека и разумных машин

Взаимодействие человека и разумных машин поднимает ряд этических вопросов, которые требуют тщательного рассмотрения:

- **Права и обязанности:** Если разумные машины обретут сознание, должны ли они иметь права и обязанности, аналогичные человеческим? Как мы будем решать конфликты между людьми и машинами?
- **Достоинство и уважение:** Как мы должны относиться к разумным машинам? Должны ли мы уважать их достоинство и избегать эксплуатации?
- **Справедливость и равенство:** Как обеспечить справедливое распределение благ и ресурсов между людьми и машинами? Как предотвратить дискриминацию и неравенство в отношениях между ними?
- **Ответственность:** Кто будет нести ответственность за действия разумных машин? Как мы будем наказывать их за нарушения и ошибки?

Таким образом, искусственный интеллект представляет собой одну из наиболее важных и сложных областей исследования в современной философии. Создание сильного ИИ может привести к радикальным изменениям в нашем мире и поставить перед нами новые этические и философские вызовы. Мы должны быть готовы к этим вызовам и разработать этические принципы и нормы, которые обеспечат безопасное и справедливое сосуществование человека и разумных машин.

Постлюди (постчеловек) и киборги.

Концепция постчеловека занимает центральное место в трансгуманистической философии и вызывает оживленные дискуссии в современном обществе [8]. Постчеловек представляет собой гипотетическое существо, которое прешло биологические ограничения человека благодаря технологическому развитию. Это может включать в себя радикальное продление жизни, улучшение когнитивных способностей, расширение физических возможностей и даже слияние с искусственным интеллектом.

Концепция киборга, организма, объединяющего в себе биологические и искусственные компоненты, возникла в середине XX века на стыке научной фантастики и кибернетики. Первоначально термин «киборг» использовался для обозначения человека, чьи физиологические функции были расширены или дополнены технологическими устройствами для выживания в экстремальных условиях, например, в космосе.

Однако, с развитием технологий, понятие киборга стало все более широким и многогранным. Сегодня киборгизация включает в себя не только использование протезов и имплантов для восстановления утраченных функций, но и применение технологий для улучшения физических и когнитивных способностей, а также для создания новых форм взаимодействия человека и машины.

1. Трансгуманистические концепции улучшения человека

Трансгуманисты рассматривают человека как проект, который может быть улучшен и усовершенствован с помощью технологий. Они предлагают различные пути достижения постчеловеческого состояния, включая:

- **Генная инженерия:** Изменение генома человека для устранения наследственных заболеваний, улучшения физических и когнитивных способностей, а также продления жизни.

- **Нейротехнологии:** Использование нейроинтерфейсов, имплантов и других технологий для расширения когнитивных возможностей, управления внешними устройствами и даже загрузки сознания в цифровую среду.

- **Нанотехнологии:** Создание нанороботов и других наноустройств, способных ремонтировать и улучшать клетки и ткани организма, а также создавать новые материалы и структуры.

- **Искусственный интеллект:** Слияние человеческого разума с искусственным интеллектом для достижения сверхчеловеческого уровня интеллекта и решения сложных проблем.

2. Сверхчеловеческие способности и их влияние на общество

Появление постлюдей и киборгов со сверхчеловеческими способностями может привести к радикальным изменениям в обществе и культуре. Некоторые из потенциальных последствий включают:

- **Социальное неравенство:** Доступ к технологиям улучшения человека может быть ограничен, что приведет к появлению нового класса «улучшенных» людей и усилению социального неравенства.

- **Изменение ценностей:** Появление постлюдей может привести к пересмотру традиционных ценностей и норм, таких как понятие человеческой природы, семьи, труда и справедливости.

- **Новые формы конфликтов:** Сверхчеловеческие способности могут быть использованы как во благо, так и во вред. Это может привести к появлению новых форм конфликтов и угроз, таких как биотерроризм и кибервойны.

- **Трансформация экономики и рынка труда:** Автоматизация и использование искусственного интеллекта могут привести к массовой безработице и изменению структуры экономики. Постлюди могут занять новые ниши на рынке труда, требующие высоких когнитивных и физических способностей.

3. Философские вопросы о природе человека и его будущем

Появление постлюдей и киборгов ставит перед нами ряд фундаментальных философских вопросов:

- **Что значит быть человеком?** Если человек может быть радикально изменен и улучшен с помощью технологий, то где проходит граница между человеком и постчеловеком? Что остается от человеческой природы в постчеловеческом состоянии?

- Свобода воли и ответственность: Если наши мысли, эмоции и поведение могут быть контролируемыми или изменены с помощью технологий, то насколько мы свободны в своих действиях? Кто несет ответственность за действия постчеловека?

- Смысл жизни и ценности: Как изменится смысл жизни и наши ценности в постчеловеческом обществе? Какие новые цели и стремления появятся у постлюдей?

- Будущее человечества: Какое будущее ждет человечество в эпоху постгуманизма? Будем ли мы сосуществовать с постлюдьми, сольемся с ними или исчезнем как вид?

Таким образом, появление постлюдей и киборгов представляет собой один из наиболее важных и сложных вызовов для современной философии. Оно заставляет нас переосмыслить наши представления о человеческой природе, этике, обществе и будущем. Мы должны быть готовы к этим вызовам и разработать новые философские концепции и этические принципы, которые помогут нам ориентироваться в мире постгуманизма.

Заключение. В данной статье мы рассмотрели философские аспекты появления постлюдей и киборгов, а также этические и социальные вызовы, связанные с развитием технологий, стирающих границы между человеком и машиной. Мы проанализировали концепции постчеловека и киборга, их потенциальные возможности и риски, а также влияние на наше понимание человеческой природы, идентичности и будущего.

Появление постлюдей и киборгов может привести к радикальным изменениям в обществе, культуре и экономике. Сверхчеловеческие способности, достигнутые благодаря технологиям, могут открыть новые горизонты для человечества, но также могут привести к усилению социального неравенства, изменению ценностей и появлению новых форм конфликтов.

Развитие технологий, связанных с постгуманизмом и киборгизацией, поднимает ряд сложных этических вопросов. Мы должны обеспечить справедливый доступ к этим технологиям, предотвратить их злоупотребление и разработать этические принципы, которые будут регулировать взаимодействие человека и машины.

Философские размышления о будущем человечества и его месте во Вселенной приобретают особую актуальность в эпоху постгуманизма и киборгизации. Мы должны переосмыслить наши представления о человеческой природе, смысле жизни и ценностях в свете новых технологических возможностей. Возможно, нам придется столкнуться с экзистенциальными вопросами о том, что значит быть человеком, какое будущее ждет наш вид и какое место мы займем в мире, где границы между биологическим и искусственным становятся все более размытыми.

Таким образом, появление постлюдей и киборгов представляет собой не только технологический, но и философский вызов. Мы должны быть готовы к этому вызову и открыты к диалогу о будущем человечества и его месте во Вселенной. Только так мы сможем использовать новые технологии во благо и обеспечить гармоничное сосуществование человека и машины в будущем.

Библиографический список

1. URL: Musk's Neuralink to start human trial of brain implant for paralysis patients (англ.). Reuters (20 сентября 2023). (датаобращения: 4.09.2024).
2. URL: Область исследования АНО НИИ «Цифровой интеллект» концепции Сметана В.В. «Цифровой философии»: первый этап 4-й стадии эволюции человечества. <https://diph.ru/> Материалы в исследованиях с использованием ИИ. (дата обращения: 4.09.2024).
3. Mercer, Calvin; Throten, Tracy J., eds. (2015). Religion and Transhumanism: The Unknown Future of Human Enhancement. Praeger. ISBN 978-1-4408-3325-0.
4. Сметана, В. В. Загадка сознания: в поисках определения и постижения субъективного опыта / В. В. Сметана // Исследования в области гуманитарных наук: теория, методика, практика : Сборник статей научно-практической конференции. – Ульяновск : ИП Кеньшенская В.В. (издательство "Зебра"), 2024. – С. 239-244. – EDN DSGACL.
5. Сметана, В. В. Цифровая иллюзия: метавселенная в контексте цифровой философии / В. В. Сметана // Общество и цивилизация. – 2023. – Т. 5, № 3. – С. 26-30. – EDN ZQOYFN.
6. Kriegel, Uriah (2014). Kriegel, Uriah (ed.). Current controversies in philosophy of mind. New York, NY: Routledge. p. 201. ISBN 978-0-415-53086-6.
7. Searle, John (January 1990), "Is the Brain's Mind a Computer Program?", Scientific American, vol. 262, no. 1, pp. 26–31, PMID 2294583.
8. Сметана, В. В. «Постчеловек» в концепции 4-й стадии эволюции человечества «цифровая философия» / В. В. Сметана // Контекст и рефлексия: философия о мире и человеке. – 2023. – Т. 12, № 7-1. – С. 45-50. – DOI 10.34670/AR.2023.32.82.004. – EDN WHLZPI.

THE EMERGENCE OF POSTHUMANS AND CYBORGS: BLURRING THE BOUNDARIES BETWEEN HUMANS AND MACHINES

Vladimir V. Smetana

Candidate of philosophical sciences, PhD.

Moscow, Russia. Digital Intelligence Research Institute

smetanavv@mail.ru

This scientific article is devoted to the philosophical study of the phenomenon of the emergence of posthumans and cyborgs, as well as the ethical and social consequences of the erasure of the boundaries between man and machine. The work analyzes key technological trends, such as the development of neural interfaces, artificial organs, digital consciousness and artificial intelligence, which contribute to the deep integration of man with technology and the emergence of new forms of intelligent beings.

Keywords: posthuman, cyborg, transhumanism, artificial intelligence (AI), digital consciousness, mind uploading, neural interfaces, ethics of technology, philosophy of consciousness, future of humanity.

ОТЛИЧИТЕЛЬНЫЙ ПРИЗНАК ИНТЕЛЛЕКТА. КОГНИТИВНОЕ И СТЕРЕОТИПНОЕ МЫШЛЕНИЕ. КРЕАТИВНЫЙ ГОМЕОСТАЗ РОБАСТНОЙ КВАДРИАРХИИ

Козлов Михаил Венедиктович

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

Для оптимального функционирования сложные технические системы стараются наделить искусственным интеллектом. И необходимо знать, какими свойствами должна обладать интеллектуальная система. Как правило, для создания ИИ используется симуляция интеллекта живых существ. При этом, применяемые для живых организмов понятия интеллекта мало пригодны для формирования требований, которым должны соответствовать системы с ИИ. Цель работы: сформулировать обязательный признак интеллекта, позволяющий классифицировать, биологические и технические системы, как интеллектуальные и использовать его при построении и оценке сложных технических систем; провести анализ отличий между естественными интеллектами разного уровня, варианты оптимальной работы коллективного интеллекта; оценить риски и динамику влияющих факторов, и методы противодействия такому влиянию.

Ключевые слова: негэнтропия, апперцепция, субъектно-ориентированные знания, иерархия, гетерархия, теория серых систем, квадриархия.

Введение. Постараемся проанализировать, что можно считать интеллектуальной системой, условия развития естественного и искусственного интеллекта, их динамику и влияющие факторы в виде волн индоктринации и методы противодействия такому влиянию.

В настоящее время идет активная разработка сложных технических систем, для которых требуются выполнение таких процедур как адаптация к окружающей среде, включая элементы обучения, распознавание образов и ориентации в пространстве, а также их робастность и безопасность.

Для этих целей стараются наделить такие системы неким искусственным интеллектом (ИИ) для обеспечения их оптимального функционирования по ряду параметров. И чтобы более ясно представлять себе принципы построения различных систем с ИИ, таких, как интеллектуальные агенты, нейронные сети или системы интеллектуального анализа данных, нужно знать, какими необходимыми свойствами должна обладать интеллектуальная система.

Учитывая отработанный эволюцией до совершенства механизм реагирования, адекватно ситуации, живых организмов и относительную новизну наделяния элементами интеллекта технических систем, как правило, для создания ИИ используется симуляция интеллекта живых существ. Однако для живых организмов до сих пор не возникала необходимость в формализованном понятии интеллекта.

Из имеющегося множества определений интеллекта, касающегося Хомо сапиенса можно выделить следующие: цитата из Британской энциклопедии [1]: «Человеческий интеллект, это качество психики, состоящее из способности к обучению на основе опыта, адаптации к новым ситуациям, понимания и применения абстрактных концепций и использования знаний для управления окружающей средой. И для ИИ «Искусственный интеллект, это способность цифрового компьютера или управляемого компьютером робота выполнять задачи, обычно присущие разумным существам»:

Отражая взгляды множества исследователей, представленные определения охватывают основные свойства интеллекта. Однако они недостаточно четки и мало пригодны для формирования требований, которым должны соответствовать системы с ИИ. Исходя из этого, сформулируем обязательный признак интеллекта, позволяющий классифицировать, как естественные биологические, так и технические системы, как интеллектуальные и использовать его при построении и оценке сложных технических систем. А также дающий возможность провести анализ отличий между интеллектами разного уровня.

Субъектно-ориентированная оценка получаемой информации. У живых существ, обладающих способностью выработки и хранения знаний, количество информации, поступающее к ним с паттернами сигналов, будет зависеть от знаний, уже имеющихся в их памяти о подобных паттернах. И по мере увеличения знаний о полученных паттернах объем информации будет стремиться к нулю, что соответствует негэнтропийному принципу информации.

Использование негэнтропийного принципа информации для оценки уменьшения новых знаний при поступлении однотипной информации к субъекту дает необходимое основание судить о наличии у биологической или технической системы интеллекта и о его динамических свойствах. При этом следует учитывать, что для каждого сложно организованного индивидуума свойственно субъектно-ориентированное восприятие поступающей информации, которое Лейбниц назвал апперцепцией [2].

В работе [3] была рассмотрена система апперцепции (СА), как некий динамический фильтр для входной информации (рис.1).

На адаптационные параметры СА будет влиять состояние биологической системы, во многом определяемое субъектной матрицей эмоций, динамично зависящей как от внешних факторов, так и от внутренних.

Сигналы, поступающие из внешней среды на живой организм, наделенный интеллектом, в системе апперцепции проходят эмоциональную фильтрацию и оценку, формируя паттерны субъектно-ориентированных знаний (СОЗ). Восприятие информации сознанием субъекта (апперцепция) индивидуально и можно говорить о субъективном эмоциональном интеллекте.




Рис. 1. Компьютерно-мозговая модель памяти и принятия решений

На основе субъектно-ориентированной апперцепции производится выработка решения, которое может отобразиться во внешнем реагировании. На текущую апперцепцию будет существенно влиять состояние динамически изменяемой матрицы эмоций (МЭ) субъекта. Это состояние будет определяться данными о среде обитания, внутреннем состоянии организма, имеющимися ресурсами, ранее полученными и упорядоченными знаниями и навыками, и выбранными целями.

С учетом наличия у каждого индивидуума субъектно-ориентированного апперцепционного фильтра с динамически изменяющимися параметрами, по-видимому, следует рассматривать вновь получаемую информацию, как субъектно-ориентированную оценку I_{st} недостатка информации, извлекаемой из поступающего сигнала с объекта исследования в момент t по отношению к сохраняемым СОЗ о нем. С учетом этого представим оценку I_{st} в виде функционала

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

где: $AKE_{t-1} * MO_{t-1}$ – априорная субъектная оценка достоверности СОЗ на момент времени $t-1$ об объекте исследования, являющаяся функционалом обработки на этот момент времени присущей модели объекта наблюдения информации MO_{t-1} оператором AKE_{t-1} . Оператор AKE_{t-1} включает в себя функции динамически меняющегося апперцепционного фильтра, 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 субъектная оценка достоверности накопленных СОЗ об объекте исследования на момент времени t , $AKE_t * MO_t \in \{0, \dots, 1\}$.

Масштаб неопределенности искомой информации, заложенной в модели объекта наблюдения, будет зависеть от информационной ценности этого объекта для субъекта и его технических возможностей.

Оператор AKE_t , играет важнейшую роль в формировании субъектных знаний. Он динамичен и связан с состоянием МЭ субъекта. И для разных субъектов вследствие его действия окраска, получаемых субъектных знаний об объекте, может значительно отличаться и даже быть, как положительной, так и негативной.

Возможна ситуация, когда при накоплении знаний об объекте, креативный субъект пересматривает модель объекта наблюдения информации MO_{ti} . И субъектно-ориентированная оценка недостатка дополнительной информации I_{sti} на некоторое время возрастает с последующим уменьшением при дальнейшем увеличении знаний. Таким образом, добываются новые, ранее не известные 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.

В живых системах эмоции нацелены на выживание индивидуума и его вида. И проведенные под руководством нейробиолога Антонио Дамасио исследования функционирования головного мозга показали важную роль эмоций в выработке решений человеком [4]. Поэтому, включение МЭ в СА субъекта при оценке его интеллекта необходимо. И из детального анализа выражения (1) применительно к ИИ можно сделать вывод, что использование выражения «Искусственный интеллект» возможно только к техническим системам, которые будут снабжены адаптивными матрицами искусственных эмоций (МИЭ). И здесь следует вспомнить основателя работ по ИИ Марвина Мински, который в [5] написал «Вопрос не в том, что умные машины могут иметь какие-либо эмоции, а в том могут ли быть умными машины без эмоций».

Формирование навыков и стереотипов мышления. У человека и у высших животных процесс обработки сигнала происходит параллельно, как на бессознательном уровне, связанном с работой имплицитной (неосознаваемой) памяти, так и на сознательном уровне, связанном с эксплицитной (осознаваемой) памятью. И нейробиолог Эрик Кандел отметил, что отклик на сигнал поступает из областей головного мозга, связанных с этими уровнями, по двум нервным путям в миндалину лимбической системы, где формируется сигнал реагирования [6].

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.

При часто повторяющихся сигналах в таких биологических системах происходят эволюционные изменения процесса их обработки, который можно представить в виде, изображенном на рис. 2.




Рис. 2. Эволюция процесса обработки входных сигналов в ответную реакцию

Вначале из однотипных входных сигналов (ВС) по верхнему пути, показанному на рис. 2, в системе формируются паттерны СОЗ, на основании которых вырабатываются субъектные ответные реакции (COP).

Для консолидации СОЗ необходимо наличие эмоциональной оценки события, дефолтного состояния мозга и времени на формирование СОЗ в этом состоянии. Этим можно объяснить приведенные в журнале Nature результаты исследований эмоционально шокирующего воздействия на человека, показавшие селективное и ретроактивное усиление воспоминания, после 6 часов и более, о произошедшем в паре с шоком события [7].

В дальнейшем при стабильном уменьшении получаемого количества новой информации I_{st} , ниже определенного порога в выражении (1), в биологической системе вырабатывается стабильная реакция, которую условно можно назвать субъективной моделью навыков (СМН). И при поступлении подобных сигналов, ответная реакция идет по значительно более быстрому нижнему пути.

Так осуществляется эволюционная цепочка восприятия информации как Неосознанная – Осознанная – Подсознательная. Можно говорить о первичности интеллекта относительно выработанного на его основе вновь приобретенного инстинкта.

В плане психологии поведения человека вырабатываемые навыки можно рассматривать, как формируемые стереотипы мышления, которые позволяют снизить время на реагирование и сэкономить энергетические ресурсы человека, а иногда сохранять здоровье, так, например, переход к СМ многим помогает поддерживать кровяное давление в норме. Но, с другой стороны, СМ может приводить к существенным ошибкам при исследовании новых явлений, изменении привычной ситуации или среды обитания.

От иерархии к аттракторам гетерархии и обратно через волны индоктринации. Потребность в робастной квадриархии. В современных условиях массовая индоктринация может привести к абсолютной глобальной иерархии со всеми ее негативными последствиями по резкому снижению творческого потенциала индивидуумов. Это неизбежно приведет к нарушениям в деятельности коллективного разума, опирающегося на разнообразие КМ множества индивидуумов. И может доминирующую небольшую группу глобалистов, со свойственным им малым горизонтом прогнозирования и сложившимся СМ прогрессистов, верящих в безграничные возможности ИИ, стимулировать к потребности в создании супер ИИ для поддержания квазиблагополучия человеческого общества. Как следствие, это будет пик волны индоктринации, приводящей к пороговому значению плотности лиц с КМ (Creators density). После этого, как обычно, возникнут аттракторные структуры гетерархии, противодействующие индоктринации и стимулирующие массовое КМ. Однако, в следствии естественной конкурентной борьбы вновь может произойти доминирование наиболее успешного аттрактора в гетерархии КМ и в результате это приведет к новой иерархии.

Для оптимизации функционирования аттракторов коллективных интеллектов, действующих в условиях неопределенности и неточных данных, предлагается на основе методов, используемых в таких теориях как GreySystem [8] и робастные системы [9], рассмотреть переход от иерархической структуры

управления к некоей квадриархии, действующей по правилам гетерархического гомеостаза. При этом, в силу естественной конкуренции Творцов возможны небольшие волны индоктринации.

С учетом перспектив развития ИИ креативные особенности каждого индивидуума могут быть обеспечены симбиозом Человека-Творца и его AlterEgo – Сильного ИИ. Человек в новых условиях усиливает свою роль Творца, который часто действует иррационально и интуитивно, а Сильный ИИ становится его глубоко индивидуальным, эффективным, рациональным помощником. И при наличии квадриархии в организации общества это позволит поддерживать эволюционно развивающуюся, плодотворную и робастную систему коллективного разума.

Библиографический список

1. Robert J. Sternberg. Human intelligence. Encyclopaedia Britannica.
2. *Leibniz: Selections*. Edited by Philip P. Wiener. New York: Charles Scribner's Sons, 1982.
3. Kozlov M. Computer-Brain Model Memory and Decision-Making. Functional Neurology, Rehabilitation, and Ergonomics. Vol.7, No. 3 (2019) – Pp.5-13.
4. A. Damasio. *Self Comes to Mind: Constructing the Conscious Brain*. Pantheon. 2010.
5. Minsky M. *The Society of Mind*. Simon and Schuster. 1988.
6. Kandel E. R. *In Search of Memory: The Emergence of a New Science of Mind*. N. Y.: W. W. Norton & Company, 2007.
7. Dunsmoor J.E, Murty V.P, Davachi L, Phelps E.A. Emotional learning selectively and retroactively strengthens memories for related events. *Nature*. 2015. Pp. 345-348
8. Mu-Shang Yin, *Fifteen years of grey system theory research: A historical review and bibliometric analysis* Expert Systems with Applications, 2013.
9. Brian D. O. Anderson, et. al. *Stability of Adaptive Systems. Passivity and Averaging Analysis*. The MIT Press. 1986.

DISTINCTIVE FEATURE OF INTELLIGENCE. COGNITIVE AND STEREOTYPICAL THINKING. CREATIVE HOMEOSTASIS OF A ROBUST QUADRIARCHY.

Mikhail V Kozlov

Institute of Integration and Professional Adaptation,
Israel, Netanya
19mike19k@gmail.com

For optimal functioning, complex technical systems are trying to endow with artificial intelligence. And it is necessary to know what properties an intelligent system should have. As a rule, to create AI, the simulation of the intelligence of living beings is used. At the same time, the concepts of intelligence used for living organisms are of little use for forming the requirements that systems with AI must meet. The purpose of the work: to formulate a mandatory feature of intelligence that allows classifying biological and technical systems as intelligent and using it in the construction and evaluation of complex technical systems; to analyze the differences between natural intelligences of different levels, options for optimal operation of collective intelligence; to assess the risks and dynamics of influencing factors, and methods of counteracting such influence.

Keywords: negentropy, apperception, subject-oriented knowledge, hierarchy, heterarchy, grey system theory, quadriarchy.

Секция: Искусственный интеллект и безопасность

УДК 004.032.26

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ КАК ОБЪЕКТ КИБЕРАТАК: УЯЗВИМОСТИ СИСТЕМ, РИСКИ

Тринчин Вячеслав Вячеславович

Институт Бизнеса БГУ,
220004, Беларусь, г. Минск, ул. Обойная, 7
viartrinchin13@mail.ru

В статье представлены ключевые архитектурные уязвимости систем искусственного интеллекта, такие как атаки на данные для обучения и адвесериальные атаки на нейронные сети, а также атаки типа «отравленных данных». Представлены возможные ущербы от атак с использованием ИИ-систем. Описаны механизмы, с помощью которых злоумышленники могут манипулировать моделями ИИ, вводя их в заблуждение и нарушая их функциональность.

Ключевые слова: Кибератаки, ущербы, риски, архитектурные уязвимости, адвесериальные атаки, data poisoning, информационные атаки.

Введение. В последние десятилетия искусственный интеллект или ИИ стал неотъемлемой частью критически важных инфраструктур, проникая в такие сферы, как национальная безопасность, здравоохранение, экономика и финансы, транспорт, промышленность и сфера услуг. Однако, несмотря на очевидные преимущества ИИ, его возрастающая сложность и зависимость от данных создают новые векторы для кибератак. В условиях растущей интеграции ИИ в сложные автоматизированные системы, устойчивость самих ИИ-алгоритмов к злонамеренным вмешательствам становится приоритетной задачей. В данной работе исследуются ключевые уязвимости систем ИИ, связанные с их архитектурой, обучением и эксплуатацией.

Статистика кибератак с технологией ИИ, предполагаемые последствия. В 2024 году группа по исследованию компьютерных преступлений, Computer Crime Research Center (далее CCRC), заявила, что в ближайшие 2 года киберпреступники активно начнут использовать ИИ для расширения количества инструментов атак. ИИ начнет применяться для более эффективной разработки новых вариантов вредоносного ПО и программ-вымогателей [2].

Согласно данным CCRC, объем ущерба от киберпреступлений к 2025 году достигнет 12 триллионов долларов. Исследователи ссылаются на данные CheckPoint и Orange CyberDefense, которые утверждают рост динамики кибератак и программ вымогателей усовершенствованные ИИ за 2023 год [2].

Искусственный интеллект помогает киберпреступникам создавать сложные и целенаправленные атаки благодаря продвинутым лингвистическим техникам, включая увеличение объема текста, пунктуации и длины предложений. Эксперты отмечают, что в 2024 году кибервымогательство и хактивизм про-

должат набирать обороты. Прогнозируется увеличение числа случаев кибервымогательства на 30-50%, причем наиболее уязвимыми окажутся корпорации, малый и средний бизнес, а также государственные структуры.

Исследователи международной газеты “Rick Analysis” рассматривали влияние кибератак с использованием ИИ на глобальную торговлю. Эксперты говорят, что такие атаки используют алгоритмы для сканирования систем на наличие уязвимостей быстрее и в большем масштабе, чем атаки, которые ведутся человеком. Вредоносное ПО, управляемое искусственным интеллектом, может изменять свой код, чтобы избежать обнаружения и удаления, делая существующие меры кибербезопасности менее эффективными, говорит исследователь Рехаб Осман из Оксфордского университета Брукса и инженер по кибербезопасности Шериф Эль-Генди. Экспорт Китая может упасть на 8,2%, прогнозируют исследователи в области экономики и кибербезопасности, в то время как в США может наблюдаться сокращение на 5,6% в симуляционном сценарии с большим количеством нарушений кибербезопасности [2].

Стоит отметить также уязвимость обычного человека перед атаками связанные с ИИ. Подобные атаки направлены на угрозу жизни или здоровья, «травлю» и унижение достоинства личности в интернете, нарушение свободы, личной неприкосновенности, тайны переписки и телефонных разговоров, финансовый или иной материальный ущерб, а также нарушение других конституционных прав человека [1].

Архитектурные уязвимости систем Искусственного Интеллекта. Архитектурные уязвимости ИИ возникают на различных уровнях системы – от ввода данных до принятия решений. Они могут проявляться как в глубине модели, так и в конфигурациях сетей или механизмов обучения. Основные виды уязвимостей включают: уязвимости нейронных сетей заключается в сложности и непрозрачности работы глубоких нейронных сетей, что делает их уязвимыми для адвесериальных атак (adversarial attacks) [3]. Такие атаки предполагают минимальные, на первый взгляд, изменения во входных данных, которые, тем не менее, могут привести к значительным ошибкам в работе модели. Важным аспектом является то, что эти изменения остаются незаметными для человека, но способны кардинально изменить интерпретацию данных ИИ-системой.

Искусственный интеллект обучается на больших объемах данных, и если данные, поступающие в систему, искажены или недостаточно качественны, это создает предпосылки для ошибок в работе модели. Архитектурные решения, связанные с очисткой и предобработкой данных, имеют критическое значение. Если системы не могут обнаружить аномалии или вредоносные изменения в данных, это открывает возможности для атак.

Глубокие нейронные сети и другие сложные модели ИИ чувствительны к малым изменениям в их архитектуре. Ошибки в проектировании сети, например, выбор неподходящих гиперпараметров или архитектурных слоев, могут приводить к недооценке модели или чрезмерному усложнению [4]. Эти ошибки снижают эффективность модели и делают её уязвимой для атак, когда злоумышленник целенаправленно изменяет входные данные с целью получения некорректных предсказаний. Инфраструктура, используемая для развертывания

ИИ, может быть неустойчива к внешним воздействиям. Например, распределенные вычислительные системы, используемые для обучения и эксплуатации моделей, могут стать целью атак, нацеленных на доступ к узлам сети, перехват данных или внедрение вредоносного кода. Устаревшие библиотеки или неправильно настроенные системы безопасности – это дополнительные точки уязвимости.

Data Poisoning или атаки типа «отравление данных». Атаки типа «отравление данных» (data poisoning) представляют собой одну из самых опасных и разрушительных уязвимостей архитектуры ИИ. Цель этих атак – манипуляция исходными данными таким образом, чтобы негативно повлиять на поведение обучаемой модели [5].

Злоумышленники могут внедрять вредоносные или искаженные данные в набор для обучения, что приводит к обучению модели на ложных данных. В результате, модель может делать ошибочные предсказания или выполнять некорректные действия в реальных сценариях. Такие атаки особенно опасны для систем, работающих в критических областях, например, в финансовом секторе или в сфере кибербезопасности.

Атаки на «отравление данных» могут быть целевыми и неконкретными [5]. Целевые атаки направлены на то, чтобы повлиять на решение модели в строго определенной ситуации. Неконкретные атаки же ставят цель снизить общую производительность модели или вызвать неожиданные ошибки в различных сценариях.

Примером целевой атаки может быть ситуация, когда модель, обученная на отравленных данных, начинает корректно работать в 99% случаев, но в критически важный момент, например, при распознавании лица конкретного человека, совершает ошибку. Неконкретные атаки могут снизить точность модели на широком наборе задач.

Адвесерияльные атаки, их механизмы и последствия. Адвесерияльные атаки являются одной из наиболее изощренных угроз, направленных на системы ИИ. Их суть заключается в создании специальных входных данных, которые предназначены для введения модели в заблуждение. В большинстве случаев такие данные минимально отклоняются от нормальных, что делает их трудноразличимыми для традиционных средств мониторинга и защиты. Атаки на классификаторы в системах, занимающихся классификацией изображений, звуковых сигналов или текстов, могут быть использованы для манипулирования результатами работы модели. Классическим примером является изменение пикселей изображения таким образом, что система ИИ интерпретирует его неправильно, например, классифицируя изображение стоп-таблички как знак «скорость не ограничена» [6].

Подобные атаки могут также осуществляться в реальном времени, что представляет особую опасность для систем, функционирующих в автономном режиме, таких как беспилотные транспортные средства или системы видеонаблюдения. В таких случаях искажение данных может привести к неправильным решениям, угрожающим безопасности и жизни людей.

Атаки на доверие к системам ИИ. Нарушение работы ИИ-системы вследствие успешной атаки может подорвать доверие не только к отдельной

системе, но и к ИИ как технологии в целом. В условиях, когда ИИ используется в таких критически важных сферах, как здравоохранение, оборона или управление национальной инфраструктурой, любая успешная атака на ИИ может иметь катастрофические последствия как на уровне организации, так и на уровне государства [6].

Информационные атаки (Model Inversion и Model Extraction) направлены на извлечение внутренней информации о модели или её данных. Злоумышленники могут использовать такие атаки для восстановления исходных данных, используемых для обучения модели, что особенно опасно в контексте систем, работающих с конфиденциальной или персональной информацией [7].

Заключение. Искусственный интеллект, являясь мощным инструментом для автоматизации и улучшения процессов в различных областях, также представляет собой важный инструмент для кибератак. Его интеграция в социально важные инфраструктуры подчеркивает необходимость обеспечения его безопасности. Архитектурные уязвимости ИИ-систем, включая атаки на данные для обучения и адвесериальные атаки, ставят под угрозу их функциональность и надежность. Компрометация данных и целостности моделей может привести к значительным последствиям как для отдельных систем, так и для широкой инфраструктуры.

Обеспечение устойчивости ИИ к таким атакам требует комплексного подхода, включая защиту данных, развитие устойчивых к атакам алгоритмов и внедрение методов мониторинга. Будущее развитие ИИ должно включать улучшение механизмов безопасности, чтобы минимизировать риски и повысить доверие к этим системам. Взаимодействие научного сообщества и промышленности, а также постоянное совершенствование методов защиты будут ключевыми для успешной и безопасной интеграции ИИ в современные и будущие технологии.

Библиографический список

1. <https://habr.com/ru> – ИИ в безопасности. [Электронный ресурс]. Режим доступа: <https://habr.com/ru/articles/798191/> – Дата доступа: 10.09.2024
2. <https://rossaprimavera.ru> – Экономическая война. Взаимоотношение Китая и США [Электронный ресурс]. Режим доступа: <https://rossaprimavera.ru/news/240650a7> – Дата доступа: 10.09.2024
3. <https://www.unite.ai/ru> – Основные уязвимости LLM. [Электронный ресурс]. Режим доступа: <https://www.unite.ai/ru/10-основных-уязвимостей-llm/> – Дата доступа: 10.09.2024
4. <https://habr.com/ru> – Гиперпараметрический поиск и оптимизация моделей. [Электронный ресурс]. Режим доступа: <https://habr.com/ru/companies/otus/articles/754402/> – Дата доступа: 10.09.2024
5. <https://www.computerra.ru> – Data poisoning или отравление данных. [Электронный ресурс]. Режим доступа: [https://www.computerra.ru/301689/data-poisoning-ili-otravlenie-dannyh-horoshaya-li-eto-ideya-ispolzovat-kiberataku-vo-bлаго/#:~:text=Data%20Poisoning%20\(отравление%20данных\)%20–,этой%20модели%20или%20манипулировать%20ею.](https://www.computerra.ru/301689/data-poisoning-ili-otravlenie-dannyh-horoshaya-li-eto-ideya-ispolzovat-kiberataku-vo-bлаго/#:~:text=Data%20Poisoning%20(отравление%20данных)%20–,этой%20модели%20или%20манипулировать%20ею.) – Дата доступа: 10.09.2024
6. <https://ib-bank.ru> – Социнженерия 2.0. Гадание на доверенном ИИ. [Электронный ресурс]. Режим доступа: <https://ib-bank.ru/bisjournal/post/2099> – Дата доступа: 10.09.2024
7. Rongke Liu, Dong Wang, Yizhi Ren, Zhen Wang, Kaitian Guo, Quaqian Qin, Xiaolei Liu. Unstoppable Attack: Label-Only Model Inversion via Conditional Diffusion Model [Текст] / Rongke Liu, Dong Wang, Yizhi Ren, Zhen Wang, Kaitian Guo, Quaqian Qin, Xiaolei Liu // IEEE transactions of information forensics and security. – 2023. – №19. – С.3958-3973. – Дата доступа: 10.09.2024

ARTIFICIAL INTELLIGENCE AS AN OBJECT OF CYBERATTACKS: SYSTEM VULNERABILITIES, RISKS

Viacheslav V. Trinchin

School of Business BSU,
Str. Oboynaya, 7, Minsk, Belarus, 220004
viartrinchin13@mail.ru

This work delves into the architectural vulnerabilities of artificial intelligence (AI) systems, with a specific focus on data poisoning and adversarial attacks. It investigates how malicious actors can compromise training data to introduce systemic errors into AI models, and how adversarial attacks can subtly alter input data to mislead AI systems and significantly affect their performance. The work also explores the broader implications of these attacks, including their potential to undermine trust in AI technologies and compromise information security. It emphasizes the critical need for a multifaceted approach to AI security, which includes safeguarding data, developing robust algorithms that can withstand attacks, and implementing effective monitoring practices to ensure the ongoing reliability and integrity of AI systems.

УДК 004.8

ВОПРОСЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В БЕЗОПАСНОСТИ

Лещинский Богдан Сергеевич

Военная академия связи им. С.М. Буденного,
194064, Россия, г. Санкт-Петербург, Тихорецкий пр-кт, д.3
dnr_1910@mail.ru

Васильев Никита Алексеевич

Военная академия связи им. С.М. Буденного,
194064, Россия, г. Санкт-Петербург, Тихорецкий пр-кт, д.3
vasn2020@mail.ru

Хабушев Рафаель Ряхимжанович

Военная академия связи им. С.М. Буденного,
194064, Россия, г. Санкт-Петербург, Тихорецкий пр-кт, д.3
vasn2020@mail.ru

Назаров Александр Русланович

Военная академия связи им. С.М. Буденного,
194064, Россия, г. Санкт-Петербург, Тихорецкий пр-кт, д.3
alieksandr.nazarov.03@mail.ru

Современные технологии кибербезопасности все чаще используют искусственный интеллект (ИИ) для борьбы с возрастающей сложностью угроз. В условиях постоянного увеличения объемов данных и многообразия атак ИИ предлагает новые подходы к защите информационных систем. Настоящая статья посвящена роли искусственного интеллекта в обеспечении безопасности: анализу его применений, сравнению с традиционными методами защиты, оценке эффективности и рисков, а также обсуждению будущих перспектив развития. В статье приводятся примеры реальных приложений ИИ в кибербезопасности, рассматриваются

релевантные научные работы и обсуждаются проблемы этического характера, связанные с использованием ИИ.

Ключевые слова: искусственный интеллект, кибербезопасность, машинное обучение, анализ угроз, нейронные сети, фишинг, большие данные, автоматизация безопасности, защита данных, прогнозирование атак.

Введение. С каждым годом значимость информационной безопасности возрастает, так как цифровизация затрагивает все больше аспектов жизни общества. С ростом объемов данных и сложностью атак традиционные методы защиты, такие как антивирусные программы и брандмауэры, становятся недостаточными для обнаружения и предотвращения новых видов угроз. Искусственный интеллект предлагает мощные инструменты для борьбы с этими вызовами, предоставляя возможность автоматического анализа больших объемов данных, прогнозирования кибератак и адаптации к новым типам угроз.

Искусственный интеллект как инструмент в области безопасности. Искусственный интеллект использует машинное обучение, нейронные сети и алгоритмы анализа данных для создания более умных и эффективных решений в области безопасности. Основные направления, в которых применяется ИИ в кибербезопасности, включают:

1. Обнаружение и предотвращение атак. ИИ автоматически выявляет аномалии в сетевом трафике или данных, что позволяет обнаруживать вредоносные программы или необычное поведение пользователей.

2. Автоматизация рутинных процессов. ИИ берёт на себя выполнение задач, связанных с мониторингом, анализом и реагированием на инциденты. Это значительно снижает нагрузку на IT-специалистов и сокращает время реакции на угрозы.

3. Анализ и прогнозирование. Используя исторические данные, ИИ может предсказывать потенциальные атаки, определять уязвимые участки в системах и предотвращать будущие вторжения [1].

Обнаружение угроз: использование машинного обучения. Одной из самых распространенных областей применения ИИ в безопасности является обнаружение угроз с использованием методов машинного обучения (МО). МО обучается на наборах данных, содержащих информацию об известных атаках, и затем используется для анализа текущей сетевой активности и поиска отклонений от нормального поведения. Среди методов МО можно выделить следующие:

1. Классификация. Использование таких алгоритмов, как наивные байесовские классификаторы и деревья решений, для обнаружения вредоносных файлов и подозрительных действий.

2. Кластеризация. Этот метод позволяет группировать похожие элементы данных (например, подозрительные IP-адреса), выявляя возможные угрозы.

3. Анализ временных рядов. Использование временных рядов для мониторинга сетевого трафика и выявления аномальных изменений [2].

Сравнение ИИ с традиционными методами защиты. Традиционные методы киберзащиты, такие как брандмауэры, антивирусные программы и си-

стемы обнаружения вторжений, до сих пор играют важную роль в обеспечении безопасности. Однако их эффективность снижается из-за растущей сложности угроз и более частых кибератак. Рассмотрим ключевые различия между подходами ИИ и традиционными методами.

Реакция на неизвестные угрозы. Традиционные системы безопасности полагаются на сигнатуры, созданные на основе ранее известных атак. Это делает их уязвимыми к новым видам угроз, которые могут не иметь известных паттернов. ИИ, напротив, использует методы обучения на данных и анализа поведения, что позволяет ему обнаруживать новые атаки, даже если они не похожи на предыдущие.

Скорость и масштабируемость. Искусственный интеллект может обрабатывать огромные объемы данных значительно быстрее, чем это могут сделать традиционные системы. Например, системы ИИ способны анализировать миллионы событий в реальном времени, что невозможно сделать вручную или с помощью стандартных методов защиты.

Адаптация и обучение. Традиционные методы требуют постоянного обновления и корректировки для работы с новыми угрозами. ИИ, с другой стороны, может самообучаться, улучшая свои способности к обнаружению угроз без необходимости постоянных обновлений [3].

Нейронные сети в кибербезопасности. Нейронные сети, одна из форм ИИ, широко применяются в области кибербезопасности благодаря их способности обрабатывать сложные многомерные данные и анализировать сложные паттерны. Например, для обнаружения сетевых атак можно использовать многоуровневые нейронные сети (deep learning), которые способны анализировать не только поверхностные признаки сетевого трафика, но и глубокие взаимосвязи между действиями пользователя и сетью.

Преимущества нейронных сетей:

1. Они могут обрабатывать большие объемы данных и находить скрытые паттерны.
2. Многоуровневый подход позволяет анализировать сложные аномалии и выявлять новые типы атак.
3. Нейронные сети адаптируются к новым угрозам благодаря возможности непрерывного обучения.

Однако нейронные сети требуют больших вычислительных ресурсов и времени на обучение. Более того, они могут быть уязвимы к "обману", когда злоумышленники пытаются ввести ИИ в заблуждение, предоставляя ему измененные данные [4,9].

Фишинг и социальная инженерия: как ИИ помогает защититься. Одна из наиболее распространенных кибератак – фишинг. Она основана на социальной инженерии и предполагает манипуляции людьми с целью получения конфиденциальной информации. Искусственный интеллект способен анализировать огромное количество электронных писем и сообщений для выявления признаков фишинга. Среди методов, используемых ИИ, можно выделить:

1. Анализ контекста. ИИ может анализировать текст сообщений, выявляя нетипичные выражения или фразы, которые могут указывать на фишинг.

2. Проверка подлинности отправителей. ИИ может использовать данные о репутации отправителей, чтобы отслеживать подозрительные письма, даже если они выглядят легитимно.

Примером успешного применения ИИ в борьбе с фишингом является использование алгоритмов, которые могут "обучаться" на новых типах фишинговых атак и оперативно применять защитные меры в реальном времени [5,10].

Проблемы и вызовы применения ИИ в безопасности. Несмотря на множество преимуществ, ИИ также имеет свои ограничения и вызовы, которые следует учитывать при его внедрении в системы безопасности:

1. Этика и конфиденциальность. Использование ИИ для мониторинга поведения пользователей может нарушать их право на приватность. Это требует тщательной проработки политики конфиденциальности и соблюдения законодательства.

2. Ложные срабатывания. Один из ключевых недостатков ИИ – возможность ложных положительных срабатываний, когда нормальная активность распознается как угроза.

3. Уязвимости ИИ. Алгоритмы машинного обучения могут быть уязвимы к целенаправленным атакам. Например, злоумышленники могут подать измененные данные, чтобы ввести систему в заблуждение.

4. Дефицит данных. Для обучения ИИ необходимы качественные данные. В случаях, когда данных недостаточно или они ошибочны, ИИ может работать некорректно [6,7].

Сравнение с релевантными исследованиями. Множество научных исследований подтверждают эффективность ИИ в кибербезопасности. Например, в работе Г. Кролика и соавторов ("The Role of Artificial Intelligence in Cybersecurity", 2020) показано, что системы ИИ могут снизить количество ложных срабатываний на 30% по сравнению с традиционными методами обнаружения угроз. В исследовании Й. Ванга и его команды ("AI and Machine Learning in Cybersecurity", 2021) был продемонстрирован потенциал ИИ в автоматическом обнаружении атак на основе анализа временных рядов сетевого трафика.

Кроме того, в работах В. Мура ("AI-driven Approaches to Preventing Phishing Attacks", 2019) и А. Дженнингса ("The Future of Cyber security with AI", 2022) подчеркивается, что фишинг остается одной из главных угроз, и применение ИИ позволяет значительно повысить уровень защиты от подобных атак [8].

Будущее ИИ в безопасности. В будущем можно ожидать дальнейшего роста роли ИИ в безопасности. Среди перспективных направлений:

1. Самообучающиеся системы. Развитие алгоритмов, которые смогут адаптироваться к новым угрозам без участия человека.

2. Интеграция с IoT. ИИ будет играть важную роль в защите устройств Интернета вещей, обеспечивая мониторинг и обнаружение угроз в реальном времени.

3. Повышение устойчивости к атакам на ИИ. Разработка механизмов защиты самих систем ИИ от целенаправленных атак, таких как подмена данных.

Библиографический список

1. Богачёв, Е. А., Щербаков, С. И., и Драченко, С. А. Искусственный интеллект и машинное обучение: Основы и применение в кибербезопасности. – М.: Издательство Академии Наук, 2020. – 256 с.
2. Дубровина, Н. А. Кибербезопасность в эпоху цифровой экономики. – М.: Юрайт, 2021. – 312 с.
3. Иванов, С. П., и Черняков, А. Ю. Методы и алгоритмы машинного обучения в системах информационной безопасности. – СПб.: Питер, 2019. – 368 с.
4. Козырев, А. В. Анализ данных и большие данные в системах киберзащиты. – М.: Лаборатория знаний, 2021. – 304 с.
5. Петров, В. М. Фишинг и методы борьбы с социальной инженерией. – М.: Инфра-М, 2019. – 220 с.
6. Смирнов, В. И. Обнаружение и предотвращение киберугроз с использованием технологий ИИ. – М.: Техносфера, 2020. – 192 с.
7. Шилов, А. В., и Головин, К. И. Искусственный интеллект в кибербезопасности: концепции и практические решения. – СПб.: БХВ-Петербург, 2021. – 276 с.
8. Филимонов, Д. Е., и Калягин, А. А. Прогнозирование и предотвращение кибератак на основе анализа больших данных. – М.: Высшая школа экономики, 2022. – 340 с.
9. Сидоров, И. Н. Технологии машинного обучения для информационной безопасности. – М.: Диалог-МГУ, 2018. – 245 с.
10. Хохлов, И. В. Современные подходы к кибербезопасности и угрозы будущего. – М.: Альпина Пабlishер, 2022. – 290 с.

THE USE OF ARTIFICIAL INTELLIGENCE SAFE

Leshchinsky Bogdan Sergeevich

Military Academy of Communications named after S.M. Budyonny,
Tikhoretskyave., 3, St. Petersburg, Russia, 194064
dnr_1910@mail.ru

Vasilev Nikita Alekseevich

Military Academy of Communications named after S.M. Budyonny,
Tikhoretskyave., 3, St. Petersburg, Russia, 194064
vasn2020@mail.ru

Khabushev Rafael Ryakhimzhanovich

Military Academy of Communications named after S.M. Budyonny,
Tikhoretskyave., 3, St. Petersburg, Russia, 194064
vasn2020@mail.ru

Nazarov Alexander Ruslanovich

Military Academy of Communications named after S.M. Budyonny,
Tikhoretskyave., 3, St. Petersburg, Russia, 194064
alieksandr.nazarov.03@mail.ru

Modern cybersecurity technologies are increasingly using artificial intelligence (AI) to combat the increasing complexity of threats. In the context of a constant increase in data volumes and a variety of attacks, it offers new approaches to protecting information systems. This article is devoted to the role of artificial intelligence in ensuring security: analysis of its applications, comparison with traditional methods of protection, assessment of effectiveness and risks, as well as discussion of future development prospects. The article provides examples of real-world applications in cybersecurity, examines relevant scientific papers and discusses ethical issues related to the use of AI.

Keywords: artificialintelligence, cybersecurity, machinelearning, threatanalysis, neuralnetworks, phishing, bigdata, securityautomation, dataprotection, attackprediction.

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В РЕШЕНИИ ЗАДАЧ ЭКОНОМИЧЕСКОЙ БЕЗОПАСНОСТИ И ФИНАНСОВОГО МОНИТОРИНГА

Бекетнова Юлия Михайловна

Финансовый университет про Правительстве Российской Федерации,
125167, Россия, г. Москва, пр-кт Ленинградский, 49/2
beketnova@mail.ru

В статье представлено описание подходов к автоматизации процесса выявления недобросовестных кредитных организаций на основе методов машинного обучения, что позволит контролирующим органам оперативно выявлять и пресекать противоправную деятельность, а также принимать обоснованные решения в сфере финансового мониторинга.

Ключевые слова: экономическая безопасность, финансовый мониторинг, методы выявления аномалий, машинное обучение.

Введение. Кредитные организации (и другие субъекты федерального закона от 07.08.2001 № 115-ФЗ «О противодействии легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма») – первый рубеж борьбы с незаконной финансовой деятельностью. Они призваны собирать и анализировать информацию о своих клиентах, и их финансовых операциях, и сообщать в случае выявленной подозрительной активности в Росфинмониторинг. Однако, кредитные организации также могут быть вовлечены в незаконную деятельность – осознанно покрывая теневые схемы, или по причине слабой системы внутреннего контроля.

Процессы отмывания денежных средств затрагивают различные отрасли экономики, и отражаются, например, на объемах уплаченных налогов и сборов, объемах выведенных за рубеж денежных средств, динамики создания и ликвидации российских юридических лиц, объемах внешней торговли, общем состоянии преступности, тенденциях миграции, и т.п.

Специфика анализа данных финансового мониторинга и выявления лиц и организаций, вовлеченных в отмывание доходов заключается в следующем:

1. Девиантные субъекты стремятся скрыть свою причастность к противоправной деятельности и активно маскируются под законопослушных участников, используя при этом современные информационные технологии и экспертные знания профессионалов в области финансов, юриспруденции, пр.

2. В связи с п.1 для выявления латентных правонарушений аналитикам Росфинмониторинга приходится анализировать большие объемы гетерогенных данных.

3. Проведение такого рода анализа по каждому проверяемому объекту требует от аналитика глубоких профессиональных знаний и опыта практической работы в предметной области, с одной стороны, и значительных временных ресурсов, с другой.

Аналитикам Росфинмониторинга при анализе кредитных организаций приходится оперировать большими объемами информации. По официальной информации Банка России по состоянию на 01.01.2020 на территории Российской Федерации деятельность осуществляют 442 кредитные организации и их 618 филиалов. Банковская отчетность содержит сотни параметров. Кроме того, в федеральной базе данных Росфинмониторинга по каждой кредитной организации ведется собственный учет информация – до 50 полей данных.

В дополнение к исходным данным в федеральной базе данных Росфинмониторинга формируется статистика по каждому виду объектов, и дополнительная идентификационная информация – адреса, данные документов, удостоверяющих личность, и прочее. Ведомственные данные Росфинмониторинга обогащаются сведениями из различных государственных реестров, данными о внешнеэкономической деятельности субъектов, налоговыми сведениями.

Традиционно в органах государственной власти применялся подход к проверкам объектов наблюдения, заключающийся в последовательной оценке экспертом одного объекта проверки за другим. Подобные оценки могут обладать экспертным субъективизмом [1, 2]. Кроме того, такой подход является ресурсоемким и требует существенных временных затрат.

Возрастающий объем поступающей информации (приблизительно на 20% ежегодно) приводит к снижению оперативности ее обработки. Лица, ответственные за принятие решений, вынуждены работать с субъективными результатами анализа при растянутых сроках их получения [3].

Требуется переход от последовательных экспертных проверок единичных объектов к параллельным массовым автоматизированным проверкам с учетом современных методических и инструментальных возможностей в условиях цифровой трансформации государственного управления.

Необходимым инструментом для этого могут служить современные методы анализа данных и машинного обучения. А автоматизация процесса выявления недобросовестных кредитных организаций на основе методов машинного обучения позволит контролирующим органам оперативно выявлять и пресекать противоправную деятельность.

Постановка задачи и формирование DataSet. В выборку данных для анализа вошли 334 кредитные организации, у 51 из них была отозвана лицензия. Исследуются показатели банковской отчетности формы №101, в частности рассматриваются следующие группы показателей:

- вложения в ценные бумаги;
- вложение в капиталы других организаций;
- кредиты физическим лицам;
- кредиты предприятиям и организациям;
- просроченная задолженность;
- основные средства и нематериальные активы;
- прочие активы;
- вклады физических лиц;
- средства предприятий и организаций.

Анализируется срез данных за три месяца до отзыва лицензии – на основании многолетней практики противодействия отмыванию доходов в данный период признан оптимальным т.к., с одной стороны девиантная составляющая деятельности банка успевает достаточно ярко проявиться (экспериментально установлено, что *начинает* проявляться примерно за 6 месяцев до отзыва лицензии), а с другой – еще остается достаточный запас времени для принятия мер.

Проведен ряд экспериментов по обработке данных при помощи алгоритмов бинарной классификации:

- двухклассового усиленного дерева решений,
- двухклассовой машины опорных векторов,
- двухклассовой логистической регрессии,
- двухклассового дерева решений,
- двухклассовой нейронной сети,
- двухклассовой сети Байеса,

и обнаружения аномалий – одноклассовой машины опорных векторов и поиска аномалий на основе метода главных компонент.

Для определения качества полученных моделей воспользуемся *ROC*-кривой (от англ. *receiver operating characteristic*, рабочая характеристика приемника) – это график, позволяющий оценить качество бинарной классификации. *ROC*-кривая отображает соотношение между долей объектов от общего количества носителей признака, верно классифицированных как несущие признак, и долей объектов от общего количества объектов, не несущих признака, ошибочно классифицированных как несущие признак.

Количественную интерпретацию *ROC*-кривой дает показатель *AUC* (от англ. *area under ROC curve*, площадь под *ROC*-кривой) – площадь, ограниченная *ROC*-кривой и осью доли ложно-положительных классификаций [4-6]. Чем больше *AUC*, тем качественнее алгоритм, равенство показателя 0,5 равносильно случайному гаданию.

Эксперименты выполнялись на платформе для машинного обучения *Microsoft Azure Machine Learning Studio*. В *MS Azure ML* реализованы возможности анализа данных различными методами, включая методы классификации, регрессии, кластерного анализа и поиска аномалий.

Обучение моделей и результаты. Результаты обработки данных методами классификации и поиска аномалий сведены в таблицу.

Можно сделать вывод, что алгоритм поиска аномалий на основе метода главных компонент дает более точные результаты по сравнению с алгоритмом одноклассовой машины опорных векторов. Алгоритм поиска аномалий *PCA-Based Anomaly Detection* использует 12 главных компонент, а при реализации классического метода главных компонент выделена одна главная компонента (вторая), которая позволяет классифицировать кредитные организации на вовлеченные и не вовлеченные в отмывание доходов. Организации в случае вовлеченности в отмывание доходов стараются скрыть этот факт как можно тщательнее, в связи с чем явление имеет высокую латентность. Чем больше главных компонент, тем полнее описана дисперсия, но с точки зрения решаемой за-

дачи классический метод главных компонент показал лучшие результаты по сравнению с алгоритмом поиска аномалий *PCA-Based Anomaly Detection*.

Таблица

**Метрики качества для алгоритмов оценки
вовлеченности в ОД кредитных организаций**

Метод	AUC	False Negative Rate	False Positive Rate	Accuracy	Precision	Recall
PCA	0,940	0,02	0,1	0,956	0,952	0,984
ADABoost	0,859	0,132	0,208	0,850	0,930	0,868
XGBoost	0,917	0,032	0,01	0,910	0,953	0,787
CatBoost	0,881	0,037	0,01	0,964	0,979	0,882
LightGBM	0,849	0,035	0,05	0,905	0,755	0,849
Two-class Support Vector Machine	0,897	0,263	0,167	0,760	0,933	0,737
Two-class logistic regression	0,900	0,276	0,208	0,740	0,917	0,724
Two-class decision forest	0,858	0,289	0,125	0,750	0,947	0,711
Two-class neuralnet work	0,892	0,237	0,167	0,780	0,935	0,763
Two-class Bayes Point Machine	0,792	0,1	0,1	0,900	0,884	0,900
One-Class Support Vector Machine	0,733	0,235	0,125	0,790	0,947	0,765
PCA-Based Anomaly Detection	0,715	0,217	0,125	0,776	0,953	0,788

Источник: составлено автором.

Из рассмотренных алгоритмов классификации наиболее точные результаты показал алгоритм машинного обучения, основанный на дереве поиска решений – *XGBoost*.

Результаты классификации кредитных организаций, полученные разными методами, в целом совпали, что свидетельствует об их внутренней сходимости, а также о применимости для решения практических задач финансового мониторинга.

Заключение. Определена специфика анализа объектов финансового мониторинга, в частности кредитных организаций, которая обусловлена высокой латентностью девиантных субъектов и их деятельности, большим объемом и гетерогенным характером требующей анализа и интерпретации информации, высокими требованиями к профессиональным знаниям и практическому опыту экспертов-аналитиков, а также существенными временными затратами на проведение анализа каждого отдельно взятого субъекта.

В сфере финансового мониторинга для принятия эффективных управленческих решений необходимо оперативно получать объективные оценки хозяйствующих субъектов (в частности, кредитных организаций). Что с учетом специфики предметной области исключает последовательную ручную проверку деятельности

субъектов. Автоматизация процесса выявления недобросовестных кредитных организаций на основе методов машинного обучения позволит контролирующим органам оперативно выявлять и пресекать противоправную деятельность.

В целях автоматизации анализа данных о кредитных организациях подобран математический инструментарий, позволяющий проводить диагностику вовлеченности банка в процессы отмыwania преступных доходов. Алгоритм классификации XGBoost и алгоритм поиска аномалий PCA-Based Anomaly Detection показывают приемлемую точность при решении задач финансового мониторинга, и могут быть применены для решения практических задач. Результаты классификации кредитных организаций, полученные разными методами, в целом совпали, что свидетельствует об их внутренней сходимости, а также о применимости для решения практических задач финансового мониторинга. По причине того, что в задачах финансового мониторинга «пропуск цели» (ошибка второго рода) может иметь более тяжелые последствия, чем «ложное срабатывание», предпочтительным оказывается использование результатов классификации кредитных организаций, полученных при помощи метода главных компонент.

Тем самым подтверждена гипотеза исследования о возможности диагностики вовлеченности банка в процессы отмыwania преступных доходов методами машинного обучения.

Приведенные результаты исследования могут быть использованы Банком России и Росфинмониторингом для автоматизации выявления недобросовестных кредитных организаций.

Библиографический список

1. Куркина Е.П., Шувалова Д.Г. Оценка риска: экспертный метод // Проблемы науки. 2017. № 1(14). С. 63-69.
2. Захарьян А.Г. Экспертная оценка комплексной устойчивости коммерческого банка // Коммерческие банки: Теория и практика. 2004. № 9. С. 14-19.
3. Бекетнова Ю.М., Крылов Г.О., Денисенко А.С. Проблемы управления и поддержки принятия решений в государственных органах власти на примере Росфинмониторинга // Информатизация и связь. 2018. № 2. С. 82-88.
4. Эскиндаров М.А., Соловьев В.И. Парадигмы цифровой экономики: Технологии искусственного интеллекта в финансах и финтехе // Когито-Центр. 2019. С. 325.
5. Lee J. AUC4.5: AUC-based c4.5 decision tree algorithm for imbalanced data classification. IEEE Access. 2019. P. 106034-106042. DOI: 10.1109/ACCESS.2019.2931865.
6. Zhang Q., Wang J., Lu A., Wang S., Ma J. An improved SMO algorithm for financial credit risk assessment – evidence from china's banking. Neurocomputing. 2017. P. 314-325. DOI:10.1016/j.neucom.2017.07.002.

MACHINE LEARNING METHODS IN SOLVING PROBLEMS OF ECONOMIC SECURITY AND FINANCIAL MONITORING

Yu.M. Beketnova

Financial University, Moscow, Russia, 125167
beketnova@mail.ru

The article presents a description of approaches to automating the process of identifying unscrupulous credit institutions based on machine learning methods, which will allow regulatory authorities to promptly identify and suppress illegal activities, as well as make informed decisions in the field of financial monitoring.

Keywords: economic security, financial monitoring, anomaly detection methods, machine learning.

ИСПОЛЬЗОВАНИЕ ТАМОЖЕННЫМИ ОРГАНАМИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ УПРОЩЕНИЯ ПРОЦЕДУР ТОРГОВЛИ И ОБЕСПЕЧЕНИЯ БЕЗОПАСНОСТИ ТРАНСГРАНИЧНОЙ ТОРГОВЛИ

Зиманова Мария Андреевна

Санкт-Петербургский им. В.Б. Бобкова филиал Российской таможенной академии,
192241, Россия, г. Санкт-Петербург, Софийская ул., д.52, лит. А
maz@spbrrta.ru

В данной статье рассматриваются перспективы использования технологий искусственного интеллекта для оптимизации таможенного контроля и упрощения процедур международной торговли. Особое внимание уделено возможности применения технологии искусственного интеллекта таможенными органами в контексте автоматического распознавания снимков, полученных с помощью инспекционно-досмотровых комплексов. Рекомендовано расширить применение искусственного интеллекта и нейронных сетей для повышения эффективности таможенного контроля, что способствует укреплению экономической безопасности и поддержанию прозрачности международной торговли.

Ключевые слова: искусственный интеллект; информационные таможенные технологии; таможенный контроль; цифровизация; таможенная служба.

Введение. В условиях глобальной турбулентности и возросших вызовов, возникающих перед стабильностью международных цепей поставок, приобретают все большее значение вопросы обеспечения эффективности и безопасности трансграничной торговли. Нестабильная геополитическая обстановка, сопровождающаяся беспрецедентным санкционным давлением и разрывами производственных и логистических цепочек, оказывает существенное влияние на экономическую безопасность большого числа стран, в частности, Российской Федерации. В сложившихся условиях особую роль акторов обеспечения безопасности и стабильности международной торговли выполняют таможенные органы, деятельность которых направлена на проведение тщательного контроля за перемещением товаров и транспортных средств через таможенную границу при одновременном содействии развитию международной торговли.

Актуальность темы исследования обусловлена тем, что современные информационные технологии, в частности, искусственный интеллект (AI), открывают для таможенных органов новые возможности для упрощения порядка перемещения товаров через таможенную границу, обеспечивая при этом достаточный уровень контроля. Интеграция AI в таможенные процессы позволяет обрабатывать большие массивы данных с большей эффективностью, что значительно сокращает время, необходимое на совершение таможенных операций и проведение таможенного контроля, одновременно увеличивая их точность и прозрачность. Такие преобразования не только содействуют упрощению трансграничной торговли, но и вносят вклад в повышение уровня экономической безопасности государства, что особенно важно в условиях глобальной нестабильности.

Понятие AI и систематизация производных таможенных технологий.

AI – важный элемент системы усовершенствования таможенного контроля на уровне регионального администрирования и в глобальном стратегическом плане. Поскольку данное понятие является комплексным и многосоставным, находится на стыке технического, экономического и юридического научного знания, необходимо четко определить содержание данного термина и обозначить его функциональную специфику.

AI стал одним из ведущих направлений этого процесса, превращаясь из темы научной фантастики и академических дебатов в неотъемлемую часть нашей повседневной жизни. Сегодня AI входит в множество аспектов нашего существования, становясь фундаментом для принятия решений в бизнесе, государственном управлении и личной жизни. В первую очередь это стало возможным благодаря экспоненциальному росту объемов данных и усилиям в области распределенных вычислений, что позволяет AI анализировать и интерпретировать информацию на беспрецедентном уровне.

Важно различать AI от простых автоматизированных систем, основанных на фиксированных алгоритмах. AI представляет собой динамично развивающуюся систему, способную к обучению и самостоятельному совершенствованию, что делает его инструментом, который может не только выполнять заданные инструкции, но и адаптироваться к новым условиям, предлагая инновационные решения для сложных проблем. Так, внедрение AI становится неотъемлемой частью цифровой трансформации государства и общества, предоставляя новые возможности для улучшения функционирования как отдельных организаций.

В 1956 году Джон Маккарти (Dartmouth College), Марвин Мински (Harvard University), Натаниэль Рочестер (IBM) и Клод Шеннон (Bell Telephone Laboratories) ввели термин «искусственный интеллект». Они определили его следующим образом: «Будет предпринята попытка понять, как можно заставить машины использовать язык, формировать абстракции и концепции, решать задачи, которые в настоящее время решаются людьми, а также, в конечном счете, самосовершенствоваться. Основная задача искусственного интеллекта заключается в том, чтобы машина могла действовать таким образом, который можно было бы признать разумным, подобно тому, как если бы такие действия выполнял человек» [1]. Предложенное авторами определение AI подчёркивает его ключевую цель – создание машин, способных имитировать человеческие когнитивные способности, такие как использование языка, абстрактное мышление и решение сложных задач. Важно отметить, что акцент сделан на способности машин к самосовершенствованию, что отражает амбиции разработчиков выйти за рамки простого автоматизированного выполнения задач, стремясь создать системы, которые могут самостоятельно учиться и адаптироваться. Так, AI рассматривается не просто как инструмент для выполнения запрограммированных функций, но как потенциальный аналог человеческого интеллекта, способный демонстрировать разумное поведение.

Анализ научной литературы позволяет сделать вывод о том, что внедрение перспективных цифровых технологий в таможенную деятельность является необходимым шагом для современных государств, стремящихся к повышению эффективности и обеспечению прозрачности таможенных процедур [2, 3, 4].

Российские ученые активно исследуют применение блокчейн-технологии, AI, интернета вещей и цифровых платформ для автоматизации и оптимизации процессов таможенного контроля, классификации товаров, мониторинга грузов и обмена информацией между участниками внешней торговли. Ожидается, что успешное внедрение этих технологий позволит улучшить эффективность и точность таможенных процедур, сократить издержки и время прохождения грузов через таможенные границы, а также обеспечить более высокий уровень безопасности и прозрачности внешнеторговых операций. В любом случае необходимо оценивать технологические параметры развития в широком смысле и соединять теоретические аспекты с конкретными вопросами повседневного функционирования таможенной службы. В целом приходится констатировать, что на сегодняшний день в данной сфере присутствуют значимые концептуальные наработки, но цельное видение пока что не сформировано.

Применение AI в распознавании снимков, полученных с помощью инспекционно-досмотровых комплексов (ИДК). Применение ИДК при проведении таможенного контроля сопровождается в настоящее время рядом проблемных аспектов, которые заключаются в первую очередь в неравномерном распределении нагрузки на операторов ИДК, внимание которых с течением рабочего времени рассеивается, что может привести к тому, что не все нарушения могут быть выявлены в рамках анализа снимков ИДК, более того, человеческое зрение не способно проводить анализ в кратчайшие сроки, что увеличивает время на проведение контроля. В контексте минимизации указанных ограничений целесообразно применение технологий интеллектуального анализа данных, способных значительно повысить точность и оперативность таможенных процедур.

В частности, реализация модели интеллектуального пункта пропуска и совершенствование системы управления рисками на основе данных ИДК могут трансформировать процесс таможенного контроля. Использование методов машинного обучения для автоматизированной обработки рентгенограмм представляет собой стратегическое направление развития, поскольку указанные технологии позволяют проводить последовательный анализ изображений. Такой инновационный подход позволит увеличить точность определения характеристик товаров, минимизировать человеческие ошибки и ускорит процесс таможенного контроля.

Первоначальный этап внедрения методик интеллектуального анализа данных в систему сканирования транспортных потоков начинается с интеграции искусственной нейронной сети в ИДК, поскольку эта технология значительно повышает точность автоматизированного распознавания объектов, в том числе обнаружение сокрытых товаров в режиме ускоренной обработки данных. Для настройки и адаптации алгоритмов нейросети к специфике таможенного контроля требуется обширная база данных, содержащая архивные рентгеновские изображения, весогабаритные характеристики и параметры ионизирующего излучения, полученные от предшествующих случаев перемещения товарных партий и транспортных средств.

Многослойная нейросеть анализирует изображения и распознает объекты на них, следуя сложному процессу: входной слой принимает «сырые» пиксели изображения как входные данные, которые передаются через один или несколько сокрытых слоев, где происходит их преобразование. Каждый нейрон в

скрытых слоях применяет весовые коэффициенты к входным данным; скрытые слои могут выделять и анализировать различные характеристики изображения, от простых элементов, таких как грани и углы, до более сложных паттернов, таких как формы или специфические объекты, в зависимости от сложности и глубины сети.

Каждый последующий слой обычно способен распознавать более абстрактные и сложные характеристики на основе информации, полученной от предыдущих слоев. На последнем этапе выходной слой сети использует финальные характеристики, собранные и обработанные предыдущими слоями, для идентификации объекта на изображении. Выходной слой обеспечивает окончательное решение о том, что представляет собой объект или где он находится на изображении, позволяя, таким образом, нейросети успешно распознавать и классифицировать различные объекты на основе их визуальных данных.

В качестве иллюстративного примера работы данной технологии можно привести результат распознавания объекта на основе объединения совокупности обнаруженных признаков, представленный на рис.

Для улучшения процесса обработки и анализа рентгеновских изображений целесообразно использовать комплекс программных решений и алгоритмических методов. Указанные технологии включают применение операций сегментации изображений, таких как выделение границ, применение сглаживающих пространственных фильтров, масштабирование, а также использование фильтров Винера и медианных фильтров. Дополнительно следует использовать методы разделения и слияния областей, детекторы углов, преобразование Хафа и алгоритм Виолы-Джонса для повышения точности извлечения признаков.




Рис. Результат интеллектуального анализа снимка ИДК

В контексте идентификации объектов рекомендуется применение передовых нейросетевых технологий, включая алгоритмы компьютерного зрения и машинного обучения. Рекомендуется использовать систему TensorFlow, которая представляет собой передовое решение для реализации задач машинного обучения, способное эффективно осуществлять распознавание и классификацию объектов в реальном времени. Система TensorFlow позволяет детализированно анализировать рентгенограммы, выявляя совпадения и расхождения с

эталонными изображениями на основе алгоритмического сопоставления и классификации данных [5].

Заключение. В результате исследования выявлено, что AI технологии обладают значительным потенциалом для повышения эффективности таможенного контроля и обеспечения безопасности транграничной торговли. В частности, применение интеллектуального анализа данных открывает новые возможности для автоматизированного распознавания рентгеновских изображений, полученных с помощью ИДК. Научно-обоснованной рекомендацией в данном контексте является активное расширение применения AI технологий, в том числе нейронных сетей, в практику таможенного контроля. Создание специализированных баз данных эталонных изображений и их интеграция с AI-алгоритмами позволит оптимизировать процесс принятия решений в реальном времени, минимизировать человеческий фактор, а также повысить прозрачность и эффективность таможенных процедур.

Библиографический список

1. Christopher Manning. Artificial Intelligence Definitions [Electronic Resource] // Stanford University. URL: <https://hai.stanford.edu/sites/default/files/2020-09/AI-Definitions-HAI.pdf>.
2. Афонин П.Н., Лебедева А.Ю. Колебательные процессы развития технологий в парадигме интеллектуализации пунктов пропуска // Таможенные чтения – 2023: Новые реалии внешнеэкономической деятельности: взгляд таможни, бизнеса и науки. Сборник материалов Международной научно-практической конференции. Санкт-Петербург, 2023. С. 21–25.
3. Афонин Д.Н. Применение искусственных нейронных сетей для анализа рентгеновских изображений контейнеров и транспортных средств // Бюллетень инновационных технологий. 2024. Т. 8. № 2 (30). С. 5–9.
4. Бондаренко А.О., Мищенко О.А. Актуальные направления цифровой трансформации деятельности таможенных органов // В сборнике: Особенности государственного регулирования внешнеэкономической деятельности в современных условиях. Материалы IX Международной научно-практической конференции. Ростов-на-Дону, 2022. С. 24–30.
5. Зиманова М.А. Применение в деятельности таможенных органов передовых информационных технологий // Человек. Социум. Общество. 2023. № 11. С. 219–224.

USE OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES BY CUSTOMS AUTHORITIES TO SIMPLIFY TRADE PROCEDURES AND ENSURE CROSS-BORDER TRADE SECURITY

MariaA. Zimanova

Russian Customs Academy St. Petersburg branch named after Vladimir Bobkov,
Sofiyskayast., 52, St. Petersburg, 190000, Russia
maz@spbrta.ru

This article examines the prospects for using artificial intelligence technologies to optimize customs control and simplify international trade procedures. Particular attention is paid to the possibility of using artificial intelligence technology by customs authorities in the context of automatic recognition of images obtained using inspection and screening systems. It is recommended to expand the use of artificial intelligence and neural networks to improve the efficiency of customs control, which helps to strengthen economic security and maintain the transparency of international trade.
Keywords: artificial intelligence; information customs technologies; customs control; digitalization; customs service.

ОБ ОПЫТЕ ИСПОЛЬЗОВАНИЯ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ В СФЕРЕ ИНФОРМАЦИОННОГО ПРОТИВОБОРСТВА

Рабчевский Андрей Николаевич

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

Ашихмин Евгений Георгиевич

ООО «СЕУСЛАБ»,
614066, Россия, г. Пермь, ш. Космонавтов, д. 111, корпус 3, офис 302
e.ashikhmin@seuslab.ru

В статье представлены результаты исследований различных свойств больших языковых моделей в приложении к некоторым базовым задачам информационного противоборства. Результаты исследований показывают, что в задачах анализа и генерации текстов большие языковые модели показывают выдающиеся результаты, в отличие от задач кластеризации, которые они выполняют не так эффективно. Кроме того, авторы указывают на то, что для получения наилучших результатов особую важность приобретает уровень промпт-инжиниринга, которому необходимо уделять особое внимание. Кроме того, при решении практических задач необходимо учитывать, что многие передовые модели недоступны для российских разработчиков, в то время как российские разработки еще не обеспечивают достаточного качества, в связи с чем необходимо уметь решать те же задачи более классическими методами.

Ключевые слова: большие языковые модели, LLM, предобученные генеративные трансформеры, GPT, суммаризация, кластеризация, генерация.

Введение. Большие языковые модели (LLM), такие как GPT-3, играют значимую роль в информационном противоборстве (ИП), проявляя потенциал как для создания пропаганды и дезинформации, так и для их выявления и противодействия. Так, по данным OpenAI¹, уже в начале 2021 года языковую модель GPT-3 использовали тысячи разработчиков в более чем 300 приложениях для создания более 4,5 млрд слов в день.

По мнению Дарьи Каспарьянц [1], LLM могут способствовать развитию как негативных тенденций, в частности, поляризации общества, автоматизации пропагандистских кампаний и широкому распространению дезинформации, так и позитивных, в частности, продвижению инструментов выявления пропаганды.

Рассматривая риски использования LLM для генерации пропаганды, авторы публикации [2] подчеркивают, что такие модели могут манипулировать общественным мнением, поддерживая определенные идеологии и политические взгляды.

Такое же мнение высказывается в статье [3] на сайте VC.ru, авторы которой утверждают, что ChatGPT 4 может быть использован для создания правдоподобных, но ложных сообщений, что делает его идеальным инструментом для

манипуляции общественным мнением. Подобные опасения выражаются и в статье The New York Times [4], где обсуждается возможность использования чат-ботов для распространения дезинформации. А в статье [5] описывается, как чат-боты могут ссылаться друг на друга, создавая цепочку дезинформации.

Более того, авторы публикации [6] утверждают, что GPT-3 может эффективно генерировать экстремистский контент, что увеличивает риск использования таких технологий для вербовки и радикализации.

Такие же выводы были сделаны на основании исследования, проведенного Центром по изучению и противодействию терроризму и экстремизму при Институте международных исследований Миддлбери [1], которое показало, что GPT-3 может генерировать экстремистские тексты, которые могут использоваться для радикализации пользователей и подталкивания их к насильственным действиям.

Даже главный специалист Пентагона по ИИ Крейг Мартелл «до смерти напуган» потенциалом ИИ в дезинформации, о чем он заявил, выступая на всемирной конференции DoDIIS 13 декабря 2022 года в конференц-центре Генри Б. Гонсалеса в Техасе (DVIDS) [7]. Основная опасность использования LLM, по мнению авторов статьи [8], заключается в снижении моральной ответственности при следовании советам ИИ.

Осознавая подобные риски, авторы статьи [9] обсуждают необходимость введения ограничений на использование LLM для предотвращения таких злоупотреблений, как автоматизация мошенничества и создание поддельных изображений, тем более что 43% респондентов не могут отличить дипфейк от реальности [10].

В связи с этим ведутся многочисленные исследования, которые подчеркивают важность разработки инструментов для обнаружения и противодействия дезинформации. В частности, авторы статьи [11], изучая применение LLM для обнаружения пропаганды, выявили, что такие модели, как BERT, могут эффективно классифицировать пропагандистские элементы в тексте.

Таким образом, LLM представляют как значительные возможности, так и серьезные угрозы в контексте информационного противоборства. Необходимость дальнейших исследований и разработки мер противодействия злоупотреблениям этими технологиями становится очевидной.

В то же время, интерес представляют базовые возможности LLM, изучение которых может помочь в понимании функциональных возможностей и пределов применения LLM в различных предметных областях и в том числе в сфере ИП. Именно этой теме посвящена данная публикация, в которой мы пытаемся обобщить опыт использования LLM при реализации различных задач ИП.

Метод. С точки зрения информационного противоборства можно выделить несколько основных задач, без решения которых противодействие информационным атакам было бы невозможно. Вот некоторые из них:

- выявление инфоповодов;
- выявление пользователей, вовлеченных в деструктивные явления;
- генерация ударного контента;
- генерация искусственных диалогов;

- выявление ключевых сущностей.

С точки зрения функциональных возможностей LLM нас интересовали:

- генеративные возможности;
- аналитические возможности;
- возможности обобщения информации;
- способность обработки больших объемов информации.

В каждой из перечисленных выше задач ИП мы пробовали использовать LLM и оценивали результаты применения по качеству, максимальному объему обрабатываемой информации, быстродействию и необходимым вычислительным ресурсам. В тех случаях, когда результаты использования LLM были неудовлетворительными, мы сравнивали их с более традиционными нейросетевыми технологиями. В результате исследования мы улучшили свое понимание сильных и слабых сторон LLM и их возможностей. Далее рассмотрим полученные результаты в каждой из задач ИП.

Генерация целевого контента. Одним из главных элементов создания воздействующего контента, который может быть использован как дезинформация, манипуляция или наоборот, противодействующая информация, является возможность генерации контента на заданную тему. В данной задаче основной является генеративная способность LLM. Поскольку большие языковые модели, как правило, построены на базе предобученных генеративных трансформеров (Generative Pretrained Transformers, GPT), возможность генерации для них является наиболее органичной задачей. Технология генерации ударного контента в социальных сетях так же не является чем-то тайным или неизвестным. Например, на сайте FasterCapital есть публикация, посвященная использованию ChatGPT для генерации контента в социальных сетях [12], в которой авторы показывают технологию и примеры генерации целевого контента в социальных сетях, но предупреждают, что не следует слепо доверять генерируемым текстам и указывают на необходимость внимательной интерпретации и проверки генерируемого текста.

В нашей работе мы также исследовали генеративные способности GPT для целей генерации целевого контента в социальной сети ВКонтакте, а также для генерации контента в виде комментариев, имитирующих обсуждение постов. Одна группа участников эксперимента находила в ВК случайный пост и с помощью программы генерации контента [13] создавала на тему этого поста заданное количество текстов с заданными параметрами, такими как длина текста, стиль, эмоциональная окраска и т.д. А другая группа участников с помощью программы генерации диалога [14] имитировала обсуждение текстов, созданных первой группой. В обоих случаях программа считывала из ВК пост, передавала GPT через API сам текст и промпт для генерации нужного контента. Далее сгенерированный контент размещался в ВК также через API ВК. В случае с генерацией комментариев и обсуждений было создано несколько профилей, имитирующих разных людей с различными характеристиками и случайным образом контент генерировался от имени разных профилей. Таким образом достигался эффект естественности общения. Генеративные возможности

GPT оказались на высоком уровне, качество хорошее, производительность облачной модели достаточна, обработка большого объема информации не требуется. В тоже время, для достижения эффекта наибольшей естественности диалогов возникла проблема промпт-инжиниринга, то есть создания таких заданий GPT, которые бы позволяли получать наиболее естественный диалог. Однако обсуждение этой проблемы требует отдельной публикации.

Выявление ключевых сущностей. При поиске информации в социальных сетях и на сайтах важную роль играет правильный набор ключевых слов для поиска, который наиболее релевантен предмету поиска. В практике аналитиков социальных сетей такие наборы ключевых слов называются поисковыми словарями. По некоторым темам даже существуют словари, утвержденные Минюстом РФ. В тоже время, любые, пусть даже самые совершенные, словари со временем имеют свойство устаревать, поскольку меняются имена, фамилии, адреса, локации, организации, понятия и даже термины, которые могут относиться к предмету поиска. Следовательно, чем более актуальным является словарь, тем более релевантным и полным будет результат поиска. Однако, поддержание актуальности словарей требует постоянной работы большого количества аналитиков. Вместо этого можно сократить затраты и время актуализации словарей, если поручить эту работу искусственному интеллекту.

Мы исследовали такую возможность, создав программу самообучаемого словаря на базе GPT [15], предварительно исследовав аналитические возможности в ручном режиме на примере модели Anthropic Claude, в результате чего получили увеличение релевантности поиска на 70% только за счет актуализации словаря [16]. В данном случае исследовались два основных свойства LLM, аналитические возможности и возможность обработки больших объемов информации. Для создания словарей в программе также использовались различные облачные модели Gemini 1.5 Pro, Claude 3 Sonnet, GPT-3.5 Turbo и локальная модель Llama 3.

С точки зрения аналитических возможностей все указанные модели показали хорошие результаты и смогли выявить ключевые сущности, заданные в соответствующих промптах. А вот что касается объемов обрабатываемой информации, возможности у моделей различаются:

Gemini 1.5 Pro – 1 миллион токенов;

Claude 3 Sonnet – 200 тысяч токенов;

GPT-3.5 Turbo – 16 тысяч токенов;

Llama 3 – 1 миллион токенов.

Таким образом Gemini 1.5 Pro и Llama 3 имеют наибольший объем обрабатываемой информации, но локальная модель Llama 3 требует довольно серьезных вычислительных ресурсов в отличие от облачной модели Gemini 1.5 Pro, поэтому их использование наиболее эффективно.

Выявление пользователей, вовлеченных в деструктивные явления.

Это задача по выявлению потенциально опасных пользователей социальных сетей или тех, кому требуется психологическая помощь. На первом этапе мы использовали Anthropic Claude, с помощью которого в случайно отобранной группе из 29 пользователей ВКонтакте, связанных с ПГНИУ, выявляли тех, кто

по мнению нейросети может быть вовлечен в деструктивные явления или проявляет признаки психологического неблагополучия. Для анализа нейросети были представлены данные профилей пользователей, группы, в которых они состоят, а также все опубликованные ими посты. В процессе работы выяснилось, что нейросеть не справляется с такими объемами информации и пришлось ограничить количество анализируемых публикаций.

Нейросеть выполняла анализ на основании тех методик, которым она была обучена при создании. В результате работы из 29 человек она выявила 1 пользователя, с крайне высокой степенью вовлеченности в деструктив и требующего немедленного реагирования правоохранительных органов, а также 3 пользователей, с которыми необходимо проведение профилактических мероприятий. Однако, поскольку суть методик, которыми пользовалась нейросеть нам была неизвестна, мы провели параллельный поиск в той же группе на основе текстовых маркеров (слова или фразы), предоставленными нам профессиональными психологами. Поиск проводился путем выявления маркеров в любых текстовых материалах без применения каких-то сложных нейросетевых технологий. В результате мы получили 1 крайне неблагополучного пользователя и еще 4, которые требуют внимание. При этом множества пользователей не совсем совпадали. После анализа причин несовпадения, выяснилось, что состав маркеров несколько отличался от тех признаков, по которым искала нейросеть. Однако в целом можно считать, что оба метода справились с поставленной задачей.

В то же время, LLM имела серьезные ограничения на объем анализируемой информации и результаты поиска были непредсказуемы, поскольку не было уверенности, что методика поиска научно обоснована. В отличие от нейросети, классический метод с маркерами был полностью научно обоснован, не имел ограничения по объему информации, не требовал высоких вычислительных ресурсов и имел существенно более высокую производительность.

В данном кейсе мы исследовали не просто аналитические способности, но еще и возможности обоснованного принятия решений. В целом после ручного анализа выбранных нейросетью пользователей нельзя сказать, что решения были не обоснованы, но в то же время использование такого метода не может нам гарантировать стабильный ожидаемый результат. Поэтому можно сделать вывод, что использование LLM для таких целей может носить скорее вспомогательный характер, в то время как классические методы выигрывают по всем показателям.

Выявление инфоповодов. Инфоповод это информационное сообщение, явление или событие, которое вызывает активную реакцию социальных медиа и СМИ. По сути, задача состоит из следующих этапов:

Суммаризация. После того, как поток сообщений поступил на конвейер, каждый текст должен пройти процедуру суммаризации, то есть процесс формирования краткого содержания исходных текстов с сохранением их смысла. Это снижает объем обрабатываемых данных и дает преимущество для следующих этапов программы.

Извлечение главной идеи. Из полученных кратких содержаний текстов путем повторной суммаризации извлекаются их главные идеи, которые в дальнейшем и будут использованы для объединения тематически близких текстов.

Определение категории текста. Каждому тексту присваивается категория или тематический тег, которые позволяют классифицировать эти тексты для более точных результатов в дальнейшем.

Кластеризация. Внутри категорий на основе выделенных главных идей происходит объединение текстов в группы, называемые кластерами, в которые входят только те тексты, которые объединены одной темой, событием или явлением.

Определение тем кластеров. Для каждого кластера по главным идеям текстов определяется тема, то есть такое явление или событие, которое объединяет все тексты в этом кластере. С помощью этого этапа будет сразу видно, что больше всего обсуждается в обществе.

Работы выполнялись в несколько этапов. На первом этапе в 2023 году мы анализировали 1000 текстов из новостной ленты с помощью GPT-3. Были получены отрицательные результаты, так как нейросеть крайне слабо могла классифицировать и кластеризовать сообщения. В 2024 году была предпринята очередная попытка, но уже с помощью Anthropic Claude. В этом случае результат был положительный, так как нейросеть справилась со всеми задачами.

При этом, модель демонстрировала комфортную производительность, а наибольшее количество времени (порядка 30 минут) было затрачено на написание подробного промта с инструкциями по обработке текстов в датасете. Непосредственно обработка текстов по заданной инструкции заняла не более 60 секунд.

Учитывая то, что данная модель не доступна для российских пользователей и в промышленном масштабе ее использование невозможно, мы решили реализовать ту же задачу более простыми методами.

В качестве суммаризатора была выбрана модель глубокого обучения *mbart_ru_sum_gazeta* [17,18], основанная на поддерживающей множество языков модели обработки естественного языка mBART [19], расширенной версии модели BART [20], разработанной компанией Facebook AI.

Для извлечения главных идей была использована другая модель суммаризации, способная формировать еще более краткое содержание в виде одного небольшого предложения. Была выбрана модель *rut5_base_headline_gen_telegram* [21], так как она специально обучена для генерации заголовков к статьям на русском языке. Благодаря этому, модель достаточно эффективно создает очень краткие содержания текстов относительно подобных ей моделей [22].

Для определения категорий текстов был использован сервис *GroqCloud*, в частности модель *Llama3-70b-8192*, к которой пользователям предоставляется бесплатный доступ через API. GroqCloud предоставляет мощные вычислительные ресурсы, благодаря которым скорость ответа на запрос к сервису составляет несколько сотен токенов в секунду, что является несомненным преимуществом для быстроты работы разрабатываемой системы. Модель *Llama3-70b-8192* является одной из наиболее продвинутых моделей в области обработки естественного языка на сегодняшний день, которая способна с довольно высокой точностью классифицировать текстовые данные.

Кластеризация данных подразделялась на два основных этапа: векторизация и непосредственно кластеризация полученных векторов. Для первого этапа наиболее эффективным решением было использовать модель глубокого обучения *e5-large-en-ru* [23], которая отображает тексты в 1024-мерное плотное векторное пространство и может использоваться для задач кластеризации и семантического поиска.

Одним из наиболее подходящих из плотностных методов кластеризации является HDBSCAN [24], преимуществом которого является то, что ему не нужно указывать какое количество кластеров мы ожидаем и на вход ему необходимо передать всего один параметр, характеризующий минимальный размер кластера.

Определение тем кластеров выполнялось по такому же принципу, как и определение категорий текстов. Использовалась та же модель llama3-70b-8192, в запросе к которой передаются главные идеи текстов из одного кластера, по которым определяется их общая тематика.

Таким образом, при использовании комплекса перечисленных выше методов были получены отличные результаты по качеству. Быстродействие было ниже, но зато требования к вычислительным ресурсам были не высокими, задача легко решалась на обычном ноутбуке. При этом все библиотеки и ресурсы были в открытом доступе и не имели ограничений на использование. Такую технологию уже возможно было использовать в промышленном масштабе.

С точки зрения функций LLM и возможности их замены другими средствами, LLM действительно очень хорошо выполняют суммаризацию и довольно трудно справляются с задачей кластеризации, поэтому в задаче выявления инфоповодов более эффективным является указанный выше набор методов и библиотек.

Заключение. Исследования возможностей LLM показало, что, обладая феноменальными способностями в области генерации, им нет равных в части создания целевого контента, что в ИП является одной из самых трудоемких задач. Однако следует внимательно относиться к качеству генерируемого контента, что определяется качеством промптов и выдвигает на первый план проблему промпт-инжиниринга.

В части аналитических возможностей, включая суммаризацию, классификацию и извлечение ключевых сущностей, LLM также показывают отличные результаты, существенно упрощая работу с большими объемами информации. Однако здесь на первый план выходит доступность самых передовых LLM для российских разработчиков, в то время как российские LLM пока не могут похвастаться своими способностями.

Самые низкие результаты LLM демонстрируют в задачах кластеризации, что и понятно, поскольку GPT не рассчитаны на такие задачи. Для их решения вероятно целесообразнее применять специализированные методы, использование которых в комплексе с LLM может дать великолепные результаты.

Самый общий вывод состоит в том, что, хотя LLM на базе GPT и не является «волшебной палочкой», при грамотном использовании для тех задач, на которые они рассчитаны, они могут существенно упростить решение и повысить качество исполнения задач в области информационного противоборства.

Также особо стоит упомянуть, что для решения задач в реальном секторе необходимо учитывать доступность моделей для использования, что в настоящее время может накладывать серьезные ограничения на их использование. В этом случае остается надеяться, что российские разработчики в скором времени доведут качество своих моделей до мирового уровня.

Библиографический список

1. Дарья К. Большие языковые модели как инструмент влияния в информационном пространстве [Electronic resource]. 2022. URL: https://rdc.grfc.ru/2022/11/large_language_model_in_information_space/ (accessed: 07.08.2024).
2. Bagdasaryan E., Shmatikov V. Spinning Language Models for Propaganda-As-A-Service // CoRR. 2021. Vol. abs/2112.05224.
3. ИИ ChatGPT-4 стал идеальным инструментом для дезинформации [Electronic resource]. 2023.
4. Tiffany H., Stuart A. T. Disinformation Researchers Raise Alarms About A.I. Chatbots [Electronic resource]. 2023.
5. James V. Google and Microsoft's chatbots are already citing one another in a misinformation shitshow [Electronic resource]. 2023.
6. McGuffie K., Newhouse A. The Radicalization Risks of GPT-3 and Advanced Neural Language Models // CoRR. 2020. Vol. abs/2009.06807.
7. GILL J. Pentagon chief AI officer 'scared to death' of potential for AI in disinformation [Electronic resource]. 2023.
8. Leib M. et al. The corruptive force of AI-generated advice // CoRR. 2021. Vol. abs/2102.07536.
9. Anderljung M., Hazell J. Protecting Society from AI Misuse: When are Restrictions on Capabilities Warranted? 2023.
10. Ani P. Share of consumers who say they could detect a deepfake video worldwide as of 2022 [Electronic resource]. 2024.
11. Chavan T., Kane A. Large Language Models for Multi-label Propaganda Detection. 2022.
12. Chatgpt для генерации контента в социальных сетях [Electronic resource]. 2024.
13. Рабчевский А.Н. et al. Программа автоматической генерации текстов в социальных сетях: pat. 2024660511 USA. Россия, 2024.
14. Рабчевский А.Н. et al. Программа автоматической генерации диалога в социальных сетях: pat. 2024660686 USA. Россия, 2024.
15. Рабчевский А.Н., Гурьянов Д.П. Самообучаемый словарь: pat. 2024661054 USA. Россия, 2024.
16. Ашихмин Е.Г., Рабчевский А.Н., Рабчевский Е.А. Создание лингвистических словарей для систем мониторинга соцмедиа при помощи больших языковых моделей // Искусственный интеллект. Теория и практика. 2024. Vol. 1, № 5. P. 31–37.
17. Gusev I. Dataset for Automatic Summarization of Russian News // Artificial Intelligence and Natural Language. Springer International Publishing, 2020. P. 122–134.
18. MBARTRuSumGazeta [Electronic resource].
19. Liu Y. et al. Multilingual Denoising Pre-training for Neural Machine Translation. 2020.
20. Lewis M. et al. BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension. In: Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP/IJCNLP) // Hong Kong: Association for Computational Linguistics. 2019. P. 4003–4015.
21. RuT5TelegramHeadlines [Electronic resource]. URL: https://huggingface.co/IlyaGusev/rut5_base_headline_gen_telegram (accessed: 09.08.2024).
22. Анализ применимости предварительной саммаризации новостей [Electronic resource]. URL: https://github.com/andreybabynin/semantic_news_graph/issues/4 (accessed: 09.08.2024).
23. E5-large-en-ru [Electronic resource]. URL: <https://huggingface.co/d0rj/e5-large-en-ru> (accessed: 09.08.2024).
24. The hdbscan Clustering Library [Electronic resource]. URL: <https://hdbscan.readthedocs.io/en/latest/index.html> (accessed: 09.08.2024).

ON THE EXPERIENCE OF USING LARGE LANGUAGE MODELS IN THE FIELD OF INFORMATION WARFARE

Rabchevsky Andrey Nikolaevich

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

Ashikhmin Eugeny Georgievich

LLC "SEUSLAB"

Sh Kosmonavtov, 111, building 3, office 302, Perm, Russia, 614066,
e.ashikhmin@seuslab.ru

The paper presents the results of research on various properties of large language models as applied to some basic information contention tasks. The results show that in text analysis and generation tasks large language models show outstanding results, in contrast to clustering tasks, which they perform less efficiently. In addition, the authors point out that the level of prompt engineering is of particular importance and should be given special attention in order to obtain the best results. In addition, when solving practical problems, it is necessary to take into account that many advanced models are not available to Russian developers, while Russian developments do not yet provide sufficient quality, therefore it is necessary to be able to solve the same problems with more classical methods.

Keywords: large language models, LLM, pre-trained generative transformers, GPT, summarization, clustering, generation.

УДК 004.8

ИСПОЛЬЗОВАНИЕ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОБЛАСТИ СОЦИАЛЬНОЙ ИНЖЕНЕРИИ

Фадеева Ирина Павловна

Ульяновский государственный университет,
432017, Россия, г. Ульяновск, ул. Льва Толстого, 42
irfir1982@gmail.com

Смолькин Валерий Петрович

Ульяновский государственный университет,
432017, Россия, г. Ульяновск, ул. Льва Толстого, 42
surap99@mail.ru

В статье рассматривается понятие социальной инженерии, ее ключевые аспекты, включая использование алгоритмов для анализа поведения пользователей в социальных сетях и мессенджерах, выявление уязвимостей в психологии отдельных личностей и групп населения, а также создание собственных сценариев для получения доступа к конфиденциальным данным. Авторы статьи поднимают важный вопрос о необходимости разработки новых подходов к защите информации.

Ключевые слова: искусственный интеллект, социальная инженерия, фишинг, информационная безопасность, большие данные.

Введение. В настоящее время социальная инженерия является одним из наиболее распространенных методов атак на информационные системы. Её актуальность подтверждается тем, что персональные и корпоративные данные стали новой целью злоумышленников в двадцать первом веке. Масштаб социальной инженерии увеличивается с каждым годом, а такие факторы, как, к примеру, пандемия и удаленная работа способствуют увеличению инвестиций преступников в сфере информационной безопасности. В связи с этим, область социальной инженерии важно ставить под контроль вместе с ещё одной активно развивающейся системой на сегодняшний день – искусственным интеллектом.

Сегодня наблюдается стремительный рост применения искусственного интеллекта в области социальной инженерии. Обратимся к понятию «социальная инженерия». Социальная инженерия – это технологии, которые основаны на анализе больших данных и машинном обучении, именно они позволяют создавать более сложные и адаптивные методы манипуляции с целью получения конфиденциальной информации или доступа к защищённым системам. Одним из ключевых аспектов этого процесса является использование алгоритмов для анализа поведения пользователей в социальных сетях и мессенджерах, что делает возможным действенную настройку кибератак. Искусственный интеллект способен выявлять уязвимости в психологии отдельных личностей и групп населения, эффективно формулируя сообщения, перекрывающие критическое мышление потенциальных жертв. Вдобавок ко всему перечисленному, системы искусственного интеллекта уже умеют создавать собственные сценарии для получения доступа к конфиденциальным данным, делая их наиболее правдоподобными и убедительными. Это ставит перед обществом серьёзные вызовы, требуя специалистов разрабатывать новые подходы к защите информации и повышению цифровой грамотности населения. Важно осознавать, что технологии могут быть использованы как во благо, так и во вред. Поэтому ставится задача: определить, насколько может быть опасна коллаборация систем искусственного интеллекта в области социальной инженерии, а также выяснить, имеются ли у всего этого какие-либо преимущества.

Данная работа поможет привлечь внимание аналитиков IT-безопасности, специалистов по информационной и кибербезопасности, а также простым гражданам, которые не хотят попадаться в уловки мошенников и враждебных систем искусственного интеллекта.

Исследование предметной области. Анализируя взаимодействие социальной инженерии и искусственного интеллекта, можно выделить несколько ключевых аспектов, связанных с ростом угроз. Во-первых, автоматизация атак с использованием алгоритмов искусственного интеллекта позволяет злоумышленникам производить операции в ранее недоступных масштабах. Эти технологии ускоряют процесс сбора данных о потенциальных жертвах, позволяя создать целевые атаки, которые выдаются за убедительные и персонализированные. Во-вторых, использование машинного обучения позволяет злоумышленникам адаптироваться к изменениям в поведении пользователей. Например, системы могут анализировать реакцию людей на различные типы атак, улучшая

свои методы манипуляции с информацией, что создает новую модель угроз, в которой жертвы становятся неосознанными участниками взаимодействия. Дополнительно следует отметить, что интеграция систем искусственного интеллекта в социальную инженерию также приводит к возникновению необычных новых форм атак. Одним из недавних нововведений в фишинге (кибератаке), является использование генеративных моделей, на основе которых создаются фальшивые изображения, видео и аудио, которые могут вводить жертв в заблуждение, делая их уязвимыми для манипуляций. Этому подвержены все категории граждан, независимо от возраста и социальной принадлежности, что и предоставляет наибольшую опасность.

Более того, анализ данных в больших объемах, доступный благодаря искусственному интеллекту, даёт возможность злоумышленникам выявлять уязвимости и указывать на специфические слабости как организаций, компаний, так и отдельных людей. Компрометация информации через социальные сети и другие платформы становится более эффективной, так как алгоритмы могут обрабатывать и интерпретировать информацию быстрее и точнее.

Ещё одним важным аспектом противодействия новым формам атак является обучение пользователей основам кибербезопасности. Повышение осведомленности об угрозах и методов защиты поможет жертвам распознавать потенциальные риски и избегать манипуляций. Проведение регулярных тренингов и семинаров, а также создание доступных ресурсов для самообразования могут существенно снизить уровень уязвимости. Заметим, что юридическое регулирование в сфере использования искусственного интеллекта должно быть актуализировано. Необходимы нормативные акты, направленные на ограничение применения технологий для злонамеренных целей и на защиту прав граждан. Это включает в себя не только защиту персональных данных, но и регламентацию работы с алгоритмами, создающими контент, способный вводить в заблуждение.

Заключение. В результате исследования выявим – для того, чтобы противостоять угрозам, связанным с этой эволюцией информационных атак, необходимо направить усилия на разработку технологий их обнаружения и противодействия. Внедрение многоуровневых систем защиты и создание междисциплинарных команд, объединяющих экспертов из различных сфер, должно стать приоритетом. Технологические решения должны сочетаться с активной позицией общества в вопросах безопасности в сети, формируя партнёрство между правительственными структурами, бизнесом и гражданами.

Библиографический список

1. Андриевский, А. И. Социальная инженерия как угроза информационной безопасности / А. И. Андриевский, А. В. Иванов // Поиск (Волгоград). – 2022. – № 2(13). – С. 132-135.
2. Пронина, Л. Н. Социальная инженерия: коррупция как мошенничество / Л. Н. Пронина // Вестник ГОУ ДПО ТО "ИПК и ППРО ТО". Тульское образовательное пространство. – 2022. – № 2. – С. 6-8.
3. Годунова, М. С. Социальная инженерия как метод киберпреступления / М. С. Годунова, М. С. Копосова // StudNet. – 2022. – Т. 5, № 6. – С. 59. – DOI 10.55186/26584964_2022_5_6_1.
4. Кисель, Д. С. Фишинг и социальная инженерия в условиях современной автоматизации / Д. С. Кисель, Л. А. Коробова // Материалы студенческой научной конференции за 2022 год, Воронеж, 19–29 апреля 2022 года / под общ. ред. проф. О.С. Корнеевой; Воронежский гос. ун-т инженерных технологий. – Воронеж: Воронежский государственный университет инженерных технологий, 2022. – С. 116.
5. Беляев, Д. А. Социальная инженерия в XXI веке / Д. А. Беляев, А. И. Исаулова // Гуманистика в условиях современной социокультурной трансформации : материалы XI Всероссийской научно-практической конференции, Липецк, 21–22 октября 2022 года. – Липецк: Липецкий государственный педагогический университет имени П.П. Семенова-Тян-Шанского, 2022. – С. 18-21.

USING ARTIFICIAL INTELLIGENCE SYSTEMS IN SOCIAL ENGINEERING

Fadeeva Irina Pavlovna

Ulyanovsk State University,
432017, Russia, Ulyanovsk, Leo Tolstoy St., 42
irfirf1982@gmail.com

Smolkin Valery Petrovich

Ulyanovsk State University,
432017, Russia, Ulyanovsk, Leo Tolstoy St., 42
surap99@mail.ru

The article discusses the concept of social engineering, its key aspects, including the use of algorithms to analyze user behavior in social networks and instant messengers, identifying vulnerabilities in the psychology of individuals and population groups, as well as creating your own scenarios for gaining access to confidential data. The authors of the article raise an important issue about the need to develop new approaches to information security.

Key words: artificial intelligence, social engineering, phishing, information security, big data.

ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ПРОЦЕССЫ ФОРМИРОВАНИЯ ИНФОРМАЦИОННЫХ ПУЗЫРЕЙ В СОЦИАЛЬНЫХ МЕДИА

Хорошавина Ольга Николаевна

Казанский (Приволжский) Федеральный университет
420008, Россия, г. Казань, ул. Кремлевская, 18
o.khoroshavina@bk.ru

Настоящая статья исследует влияние нейросетевой алгоритмизации в социальных медиа. Раскрывается прямая связь между искусственным интеллектом и информационной выборкой. Даны рекомендации по преодолению влияния информационных пузырей, посредством улучшения качества работы алгоритмизации искусственного интеллекта.

Ключевые слова: нейросетевые технологии, социальные медиа, общественное мнение, алгоритмизация информационных пузырей.

Введение. В современном мире информация стала одним из важнейших инструментов управления общественными процессами. Ее доступность и качество могут оказывать решающее влияние на понимание обществом окружающей действительности. Формирование информационного пузыря есть процесс, в ходе которого индивиды получают и обрабатывают только ту информацию, которая соответствует их существующим убеждениям и предпочтениям.

С возникновением и стремительным развитием искусственного интеллекта в сфере информационных технологий и медиакommunikаций особенно четко прослеживаются изменения в доступе к информации. Алгоритмы нейросетей, используемые в социальных сетях, а также при настройке контекстной, таргетированной рекламы, автоматизируют процесс выборки показа объявлений. При этом, они в состоянии оказывать произвольное влияние на формирование общественного мнения, усиливая возникновение информационных пузырей. В ситуации, при которой пользователи получают только те сообщения и мнения, которые подтверждают их текущие взгляды и потребности, может проследиваться тенденция к поляризации мнений и общественным конфликтам.

Актуальность обусловлена тем, что искусственный интеллект – новая формирующая часть реальности, которая все еще активно изучается в различных аспектах [1]. Научное понимание влияния искусственного интеллекта на процессы формирования информационных пузырей актуально как для исследователей в области социологии, философии, психологии, медийных технологий, так и для практикующих специалистов, работающих в области информационных систем и социально-информационной аналитики. Данная работа посвящена осознанию процессов влияния нейросетей на формирование информационных пузырей. Автор в ходе исследования сделает попытку повысить осведомленность влияния искусственного интеллекта на процессы взаимодействия с контентом, разработать рекомендации по улучшению работы алгоритмов нейросе-

тей в социальных медиа, что поможет создать более открытое и инклюзивное информационное сетевое медиaprостранство.

В качестве методологии был выбран анализ и синтез. Работа носит общетеоретический характер, основанный на рефлексии второго порядка. Выводы сделаны на основании проведенного критического обзора литературы, прежде всего, в области информационно-коммуникационных исследований, социологии и социальной психологии.

Таким образом, исследование влияния искусственного интеллекта на формирование информационных пузырей играет первостепенную роль в понимании информационных процессов их последствий для общества.

Определение и классификация информационных пузырей в социальных медиа

Для того, чтобы дать определение информационного пузыря, целесообразно обратиться к понятию «информация». Существуют различные мнения в области определения информации. Одни исследователи утверждают, что информация – свойство всей материи, и поэтому информация является полноценной философской категорией [2]. Другие понимают информацию как свойство только человека и общества [2]. Исследователи В. И. Корогодин и В. Л. Корогодина рассматривают информацию, как основу жизни, а, значит, именуют ее свойством всей живой материи [3].

Исходя из вышеперечисленных определений, информационные пузыри формируются как часть человеческого бытия и общественных отношений. Они появляются в результате конfluence факторов, связанных с личными предпочтениями пользователя, алгоритмами платформ и социальными взаимодействиями. Основные причины формирования информационных пузырей включают:

1. Алгоритмы рекомендаций. Платформы социальных сетей и новостных агрегаторов используют алгоритмы нейросетей для анализа поведения пользователей через комментарии, лайки, глубину просмотра и предлагают контент, соответствующий их интересам. Это усиливает эффект, поскольку пользователи видят только ту информацию, которая подтверждает их уже существующие мнения.

2. Избирательность восприятия: люди склонны искать и потреблять ту информацию, которая соответствует их взглядам и убеждениям, игнорируя или отвергая альтернативные точки зрения. Алгоритмы предложенных новостей усиливают информационный пузырь, заставляя человека переходить по предложенным ссылкам, отключив критическое мышление для восприятия дальнейшей информации.

Сложность ситуации заключается в том, что с постоянным развитием и совершенствованием процессов алгоритмизации, пользователи перестали ощущать влияние информационных пузырей.

Классификация информационных пузырей по источнику информации

Социальные сети	Платформы: VK, Одноклассники Характеристика: информационные пузыри формируются через взаимодействие с друзьями, подписчиками и группами. Контент часто является результатом алгоритмической персонализации, что приводит к уменьшению его разнообразия
Новостные агрегаторы и сайты	Платформа: ЯндексНовости Характеристика: Алгоритмы выбирают новости на основе интересов пользователя и его предыдущих кликов, что приводит к формированию целевых новостных лент. Искусственный интеллект активно фильтрует информацию, игнорируя материалы, которые могут вызывать сомнения или противоречия («фильтр пузыря»)
Видеохостинги	Платформы: VK Клипы, Yappy, RUTUBE Характеристика: алгоритмы рекомендательных систем показывают видео на основе предыдущего просмотра, создавая пузыри в видеороликах по определенным темам или мнениям
Аудиоплатформы и подкасты	Платформы: VK Музыка, ЯндексМузыка, Звук Характеристика: пользователи выбирают подкасты и музыкальные волны, формируемые алгоритмами, которые подстраиваются под музыкальные вкусы и предпочтения большинства, что создает узкое, одинаковое потребление аудиоформатов
Поисковые системы	Платформа: Яндекс Характеристика: настройки контекстной и медийной рекламы используют нейросети для показа рекламы, релевантной поисковым запросам пользователей, стимулируя на импульсивные покупки, даже в случае, если человек находился еще только на стадии интереса. Это создает замкнутый контур, когда пользователь совершает целевое действие или покупку, не ознакомившись с альтернативами

Источник: составлено автором.

Данная классификация помогает лучше понять, как различные социальные медиа могут формировать информационные пузыри, способствуя эффекту изолированности и затрудняя процессы критического мышления.

Пути преодоления информационных пузырей с корректировкой использования алгоритмов нейросетей. С целью преодоления возникновения информационных пузырей в ходе влияния алгоритмизации на социальные медиа, автор статьи рекомендует использовать инновационные подходы к разра-

ботке алгоритмов в виде многофакторной фильтрации контента, смешанной модели рекомендательных систем, внедрения «случайности» в рекомендации и методики оценки качества контента. Многофакторная фильтрация контента может включать в себя использование таких алгоритмов, которые учитывают не только интересы пользователя, но и широкий спектр факторов, таких как: культурные и религиозные предпочтения, этические факторы, учет текущих ситуаций. Смешанная модель рекомендательных систем может включать в себя интеграцию различных подходов (контентный анализ, фильтрация на основе сложности) для создания более сбалансированных рекомендаций. Добавление случайных элементов в выборку контента может обеспечить доступ к материалам вне привычной зоны интересов пользователя. Разработка метрик для оценки качества источников могут использоваться алгоритмами для фильтрации контента.

Не мало важную роль в борьбе с информационными пузырями играет развитие медиаграмотности пользователей через основы обучения анализу информации, разработке онлайн-ресурсов с играми и тестами для проверки знаний и навыков медийной грамотности, а также вовлечение специалистов для проведения вебинаров, лекций, мастер-классов и семинаров, фокусирующихся на актуальных вопросах медийной грамотности.

Заключение. В результате исследования была раскрыта классификация информационных пузырей по источнику информации с нейросетевой алгоритмизацией. Продемонстрированы пути преодоления негативного воздействия информационных пузырей при помощи искусственного интеллекта. Внедрение обозначенных практик будет способствовать представлению более разнообразного контента, который может быть важен для формирования более полного взгляда на ситуации. Пользователи получают возможность открывать для себя новые темы и взгляды на знакомые вопросы, а более широкий охват различных точек зрения поможет минимизировать фильтр-пузыри. Образовательные инициативы и методики оценки качества контента обеспечат лучший контроль за качеством многообразной информации и ее восприятием. Пользователи смогут более осознанно подходить к выбору контента и развивать критическое восприятие информации, что особенно важно для молодого поколения, которое уже прочно находится в эпицентре Web-реальности.

Библиографический список

1. Якупов Б. И., Гаврилова С. А. Общение с искусственным интеллектом как форма метакommunikации: Медиа и власть: власть медиа? : Сборник материалов Всероссийской научно-образовательной конференции с международным участием (Казань, 15 мая 2024 г.). – Казань: Издательство Казанского университета, 2024 – 392 с.
2. Рыжов В. П. О понятии «информация» // Известия вузов России. Радиоэлектроника. – 2011. – № 1 С. 3–8.
3. Корогодина В. И., Корогодина В. Л. Информация как основа жизни. Дубна: Феникс, 2000. 205 с.

THE INFLUENCE OF ARTIFICIAL INTELLIGENCE ON THE FORMATION OF INFORMATION BUBBLES IN SOCIAL MEDIA

OlgaN. Khoroshavina

Kazan (Volga Region) Federal University
Str. Kremlevskaya, 18, Kazan, Russia, 420008
o.khoroshavina@bk.ru

This article examines the impact of algorithmization of neural networks in social networks. A direct connection between artificial intelligence and information sampling has been revealed. Recommendations are given on overcoming the influence of information bubbles by improving the quality of the work of artificial intelligence algorithmization.

As a result of the study, the classification of information resources according to the source of information with neural network algorithmization was revealed. The ways of overcoming the negative impact of information technologies with the help of artificial intelligence are demonstrated. The implementation of these practices will contribute to the presentation of more diverse content, which may be important for forming a more complete view of the situation. Students will have the opportunity to discover new topics and views on important issues, and a broader coverage of different points of view will help minimize filter bubbles. Educational initiatives and content quality assessment methods will provide better control over the quality of diverse information and its perception. Users will be able to choose content more consciously and develop a critical perception of information, which is especially important for the younger generation, which is already firmly located in the epicenter of Web reality.

Keywords: neural network technologies, social media, public opinion, legitimization of information bubbles.

Секция: Искусственный интеллект и экономика

УДК330.4, 330.35

РЕГРЕССИОННОЕ МОДЕЛИРОВАНИЕ НА ОСНОВЕ НЕЧЕТКО-МНОЖЕСТВЕННОГО ПОДХОДА С ПРИЛОЖЕНИЯМИ К АНАЛИЗУ ЭКОНОМИЧЕСКОГО РОСТА

*Багаутдинова Наиля Гумеровна,
Исмагилов Ильяс Идрисович, Алсаиед Гена*
Казанский (Приволжский) федеральный университет,
420008, Россия, г. Казань, ул. Кремлёвская, 18
nailya.mail@mail.ru, iismag@mail.ru, ghenaaalsaid@gmail.com

Изучение взаимосвязей между экономическими переменными имеет большое значение в эмпирических исследованиях и играет важную роль в понимании экономических проблем. Классический регрессионный анализ является одним из широко известных методов количественного изучения экономических процессов по выборочным данным. Однако в некоторых ситуациях его применение оказывается недостаточно обоснованным вследствие ряда ограничений, накладываемых в основном предпосылками методов оценивания моделей. Использование нечеткого регрессионного анализа снимает ряд ограничений его классического аппарата. В статье представлена классификация регрессионных моделей. Кратко описаны некоторые известные и предложенные методы построения нечеткой модели линейной регрессии. Приведены основные выводы по результатам применения нечетких регрессионных моделей в виде производственных функций для анализа экономического роста.

Ключевые слова: регрессионный анализ, регрессионное моделирование, регрессионная модель, нечеткая регрессия, производственная функция, экономический рост.

Введение. Моделирование и прогнозирование являются важным этапом для анализа экономических процессов. При этом широко используются методы регрессионного анализа (РА). Аппарат РА широко используется для целей анализа и планирования экономической деятельности на государственном и региональном уровнях. В классическом варианте он изучает количественные взаимосвязи между показателями экономических процессов на основе построения регрессионных моделей (РМ) на основе четких данных и четких функциональных соотношений между переменными моделей [1].

Отметим широкое применение регрессионного моделирования для анализа экономического роста (ЭР) на уровне стран и их регионов. При этом в основном используются линейные и нелинейные производственные функции (ПФ) [2]. Нелинейные модели используются в основном в мультипликативно-степенной форме (функции Кобба-Дугласа и их модификации с расширенным

набором факторов). При сравнительном изучении регионов страны по ЭР используются РМ панельных данных [3]. Отметим, что РМ в мультипликативно-степенной форме приводятся к линейному виду логарифмированием обеих частей уравнения регрессии. В итоге такого преобразования имеем лог-линейные РМ, который можно оценивать методом наименьших квадратов (МНК).

При использовании классической линейной регрессии (ЛР) в ряде случаев возникают проблемы, среди которых отметим следующие. При использовании МНК могут нарушаться его предпосылки (условия Гаусса-Маркова) [4]. Проблемы могут возникнуть, когда модель оценивается по короткой выборке, предположения о типе распределения вероятностей ненадежны или существует нечеткость между зависимыми и независимыми переменными [5]. Нечеткий РА позволяет снять ряд проблем, которые возможны при применении его классического аппарата. Методы нечеткой регрессии можно использовать при работе с данными в условиях неопределенности. С их использованием строятся нечеткие функциональные отношения между зависимыми и независимыми переменными, при этом входные данные могут быть четкими или нечеткими [6].

Методы. В общем случае методы нечеткого РА могут быть разделены на две группы. Первая группа методов базируется на МНК и его обобщениях. Этот подход, в свою очередь, имеет две разновидности, в одной из которых, используется критерий максимальной совместимости, а в другой – критерий минимизации квадратичного отклонения [7]. Вторая группа методов основано на линейном программировании. Танака Н. создал модель нечеткой ЛР, применив метод линейного программирования для оценки параметров с критерием минимума индекса нечеткости [8]. На основе метода Танаки предложен метод с использованием h-среза, использующий расширение симметричных треугольных нечетких коэффициентов до трапециевидных нечетких чисел [9]. Этот метод оптимизирует использование имеющихся данных, дает исследователю возможность вмешаться в процесс моделирования и использовать свой опыт для улучшения качества прогнозов.

На практике метод нечеткой ЛР в ряде случаев дает отдельные коэффициенты регрессии в виде четких чисел. С учетом этого нами предложена следующая классификация моделей ЛР по типу коэффициентов регрессии [6]:

1. Четкая регрессия (все коэффициенты модели являются четкими);
2. Частично-нечеткая регрессия (в модели хотя бы один нечеткий коэффициент);
3. Нечеткая регрессия (все коэффициенты модели являются нечеткими).

В [6] предложен метод построения нечетких моделей ЛР, основанный на оценивании ряда частично-нечетких моделей с дальнейшим их агрегированием в итоговую нечеткую регрессию. В этой РМ все коэффициенты регрессии задаются в нечетком виде, при этом входные данные представляют собой четкие числа, а предсказанные значения зависимой переменной описываются треугольными нечеткими числами.

В [10,11] предложен новый подход к построению нечеткой ЛР, в котором коэффициенты модели представляются в виде трапециевидных нечетких чисел. При этом входные данные также являются четкими числами, а предсказанные

значения зависимой переменной описываются трапециевидными числами. Идея предлагаемого подхода к оцениванию нечеткой ЛР основана на формировании двух выборок с использованием исходной выборки. С этой целью предварительно оценивается четкая ЛР с использованием определенного метода оценивания. Нами предложено использование для этой цели МНК и метода наименьших модулей. Их использование приводит к двум вариантам реализации предложенного подхода к построению нечеткой ЛР.

Приведем краткое поэтапное описание методов в общей постановке

Этап 1. Оценивание четкой ЛР и расчет предсказанных значений зависимой переменной.

Этап 2. Формирование двух подвыборок на основе исходной выборки:

$$\text{Первая выборка: } y_{1t} = \begin{cases} y_t, & y_t \leq \hat{y}_t \\ \hat{y}_t, & y_t > \hat{y}_t \end{cases},$$

$$\text{Вторая выборка: } y_{2t} = \begin{cases} y_t, & y_t \geq \hat{y}_t \\ \hat{y}_t, & y_t < \hat{y}_t \end{cases},$$

где y_t – фактическое значение зависимой переменной; $\hat{y}_t$ – предсказанное значение зависимой переменной по четкой ЛР.

Этап 3. Построение по каждой подвыборке частичной нечеткой ЛР с коэффициентами в виде треугольных нечетких чисел.

Этап 4. Построение нечеткой ЛР с коэффициентами в виде трапециевидных нечетких чисел с использованием коэффициентов частичных нечетких регрессий.

По построенной нечеткой ЛР определяются значения зависимой переменной в виде трапециевидных нечетких чисел вида (a_i, b_i, c_i, d_i) .

Результаты. Нечеткий РА в настоящее время начинает применяться и достаточно эффективно показывает себя на практике при моделировании и прогнозировании ЭР. Приведем в краткой форме основные выводы по результатам проведенных нами исследований. В них решались задачи моделирования и прогнозирования ЭР на примере РТ с использованием валового регионального продукта (ВРП). При этом были использованы статистические данные из официальной информации, размещённой на сайте Территориального органа Федеральной службы государственной статистики по Республике Татарстан (<https://tatstat.gks.ru>).

Исследования регионального ЭР были проведены с использованием РМ как четких, так и нечетких с использованием ПФ. Оценивание четких и нечетких РМ на основе ПФ в мультипликативно-степенной форме проводилось приведением их к линейному виду. Четкие модели оценивались в среде эконометрического пакета Gretl, реализация методов построения нечетких моделей была проведена в среде табличного процессора MS Excel с использованием надстройки Поиск решения. Для получения точечных оценок по нечетким числам использовалась операция их дефаззификации по методу центра площади.

В [12] приведены результаты исследования по моделированию регионального ЭР на основе ПФ и выбору ее наилучшей спецификации. Полученные результаты показывают, что агрегированная нечеткая РМ позволяет лучше ин-

терпретировать доверительные интервалы для эластичности по факторам экономического роста (труда и капитала). Следовательно, нечеткая ПФ позволяет сделать более адекватные выводы относительно экономической системы РТ.

Разработанные нечеткие модели регионального ЭРв виде линейных двухфакторных ПФ предложены в [11]. В результате оценки качества моделей показано, что метод нечеткой ЛР с использованием трапециевидных чисел на основе метода наименьших модулей даёт более высокую точность прогнозирования ВРП и лучше объясняет его динамику.

Результаты регрессионного анализа регионального ЭР с использованием как четкого, так и нечеткого подходов представлены в [13]. Показано, что модель нечеткой ЛР адекватно описывает зависимость ВРП в случае полной и укороченной выборки и даёт лучшую точность прогнозирования в случае укороченной выборки.

Моделирование регионального ЭР с помощью нечеткой ЛР с трапециевидными коэффициентами на основе МНК проведено в [10]. Результаты показывают, что нечеткая модель на основе предложенного метода ее построения обеспечивает лучшие точностные показатели по сравнению с четкой РМ.

Заключение. Проведенные исследования показали перспективность использования нечеткого регрессионного моделирования для анализа ЭР. Применение нечетких РМ особенно эффективно в случае коротких выборок, когда они позволяют получить более надежные прогнозные решения. Это связано с тем, что эти модели снимают ряд проблем, связанных с оцениванием четких регрессий классическими методами.

Библиографический список

1. Nataliya Chukhrova, Arne Johannssen. Fuzzy regression analysis: Systematic review and bibliography // *Applied Soft Computing*. 2019. Vol84 . [Электронный ресурс]. Режим доступа: <https://www.sciencedirect.com/science/article/abs/pii/S1568494619304892>.
2. Петухов Н.А., Горидько Н.П., Нижегородцев Р.М. Факторы экономического роста российских регионов: моделирование, анализ, прогноз. – М.: ООО «НИГЖЦ Восход-А», 2012. – 292 с.
3. Багаутдинова Н. Г., Кадочникова Е.И. К вопросу о факторах эндогенного роста в регионах // *Анализ, Моделирование, Управление, Развитие социально-экономических систем (АМУР-2023): сборник научных трудов XVII Международной школы-симпозиума. К 105-летию ФГАОУ ВО «КФУ им. В. И. Вернадского»*, Симферополь-Судак, 14–27 сентября 2023 года. – Симферополь, 2023. – С. 47-50.
4. Kim K. J., Chen H. A Comparison of fuzzy and Nonparametric Linear Regression // *Computers Ops Res.* – 1997. – Vol. 44. – Pp. 505–519.
5. Savic D.A., Pedrycz W. Evaluation of Fuzzy Linear Regression Models // *Fuzzy Sets and Systems.* – 1991. – No. 39. – Pp. 51.
6. Исмаилов И.И., Алсаиед Г. Классификация регрессионных моделей и метод построения линейных нечетких регрессий // *Инновационная экономика: информация, аналитика, прогнозы.* – 2023. – № 2. – С. 130-138.
7. Chang Y., Ayyub B. Fuzzy regression methods – a comparative assessment // *Fuzzy Sets and Systems.* -2001. – No. 119. – Pp. 187-203.
8. Tanaka H., Hayashi I., Watada J. Possibilistic linear regression analysis for fuzzy data // *European journal of operational research.* – 1989. – Vol. 40. – Pp. 389- 396.
9. Charfeddine. S.K., Zbidi. F, Mora-Camino. Fuzzy Regression Analysis using Trapezoidal Fuzzy Numbers. *EUSFLAT – LFA*. 2005. – Pp. 1213–1218.

10. Ilyas Idrisovich Ismagilov, GhenaAlsaied. Fuzzy Regression Analysis using Trapezoidal Fuzzy Numbers // Industrial Engineering & Management Systems. – 2020. – Vol. 19. – No.4. – P.896-900.
11. Исмагилов, И. И., Алсаиед Г. Оценивание нечеткой линейной регрессии с трапециевидными коэффициентами на основе метода наименьших модулей// Друкеровский вестник. – 2023. – № 5. – С. 261-271.
12. Алсаиед Гена. Построение модели регионального экономического роста на основе нечеткой производственной функции // Финансовая экономика. – 2024. – № 1. – С. 6-9.
13. Ilyas Idrisovich Ismagilov, GhenaAlsaied. Modeling gross regional product based on crisp and fuzzy regressions // Revista Turismo: estudos e práticas. – 2020. – No.4. [Электронный ресурс]. Режим доступа: <https://geplat.com/rtep/index.php/tourism/article/view/834/795>.

REGRESSION MODELING BASED ON AN FUZZY-PLURAL APPROACH WITH APPLICATIONS TO THE ANALYSIS OF ECONOMIC GROWTH

Bagautdinova Nailya Gumerovna, Ismagilov Ilyas Idrisovich, Alsaied Ghena

Kazan Federal University,
Str.Kremlevskaya, 18, Kazan, Russia, 420008,
nailya.mail@mail.ru, iiismag@mail.ru, ghenaalsaied@gmail.com

The study of the relationships between economic variables is of great importance in empirical research and plays an important role in understanding economic problems. Classical regression analysis is one of the widely known methods of quantitative study of economic processes based on sample data. However, in some situations, its application turns out to be insufficiently justified due to a number of limitations imposed mainly by the prerequisites of model estimation methods. The use of fuzzy regression analysis removes a number of limitations of its classical apparatus. The article presents a classification of regression models. Some known and proposed methods for constructing a fuzzy linear regression model are briefly described. The main conclusions on the results of applying fuzzy regression models in the form of production functions for analyzing economic growth are presented.

Keywords: regression analysis, regression modeling, regression model, fuzzy regression, production function, economic growth.

РАЗРАБОТКА ИННОВАЦИОННОГО ПОДХОДА К ИССЛЕДОВАНИЮ УРОВНЯ ПОТРЕБИТЕЛЬСКОЙ ЛОЯЛЬНОСТИ В СФЕРЕ АВИАПЕРЕВОЗОК С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Коротченко Денис Сергеевич

Санкт-Петербургский государственный университет,
199034, Россия, Санкт-Петербург, Университетская наб., д. 7–9
korotchenkods@gmail.com

Шмидт Светлана Андреевна

ООО «Яндекс Беспилотные Технологии»,
119021, Россия, Москва, ул Тимура Фрунзе, д. 11 к. 2
lana0771711@gmail.com

В статье разработана инновационная модель прогнозирования лояльности потребителя к авиакомпании. В основе представленной модели лежит дерево принятия решений. Такой подход к анализу данных позволил получить большую точность прогнозирования, чем представленный ранее нейросетевой подход. Также в рамках работы удалось выделить ключевые факторы, влияющие на лояльность пассажиров. Данное исследование может быть использовано авиакомпаниями с целью повышения спроса и потребительской лояльности.

Ключевые слова: инновационный подход, машинное обучение, математическое моделирование, искусственный интеллект, дерево принятия решений, прогнозирование, потребительская лояльность, отрасль авиаперевозок.

Введение. При выборе билета на самолет пассажиры принимают решение на основе многих параметров, одним из которых является предыдущий опыт полета рейсами той или иной авиакомпании. Построение деревьев принятия решений – иерархической структуры правил – один из простых, но эффективных методов машинного обучения для анализа и предсказания данных, отличающийся простотой интерпретации полученной модели [1].

В данной статье разработана модель оценки лояльности пассажира к авиакомпании. В основе предложенной модели лежат деревья принятия решений. Такой подход к построению модели позволил выделить ключевые факторы, влияющие на лояльность пассажиров.

В 2021 году была опубликована работа [2], в которой для решения такой задачи предлагалось использование нейросетевой модели, представляющей из себя персептрон с двадцатью двумя входными нейронами, одним выходным и одним внутренним скрытым слоем с восемью нейронами. Ошибка тестирования полученной модели составила 23%.

Данная работа демонстрирует модель, дающую меньшую ошибку тестирования, рассчитанную на тех же обучающей и тестовой выборках. Также использование деревьев принятия решений позволило обучить модель на множестве данных большего размера, что приводит к более репрезентативным ре-

результатам при анализе наиболее значимых характеристик. Значимо, что набор наиболее важных факторов отличается от результатов, опубликованных в [2].

Постановка задачи и формирование обучающей и тестовой выборки.

Для обучения и тестирования модели было найдено подходящее множество данных в открытом доступе, опубликованное в Kaggle [3].

Множество данных содержит следующие входные параметры: X1 – пол пассажира, X2 – лояльность пассажира, X3 – возраст, X4 – цель поездки, X5 – класс билета, X6 – дальность полета в километрах, X7 – WiFi во время полета, X8 – удобство времени отправления и прибытия, X9 – процесс онлайн-покупки билета, X10 – расположение выхода на посадку в аэропорту вылета, X11 – еда и напитки в полета, X12 – онлайн-регистрация на рейс, X13 – удобство посадочных кресел в самолете, X14 – досуг в полете, X15 – сервис на борту, X16 – место для ног, X17 – процесс сдачи и получения багажа, X18 – регистрация на рейс, X19 – сервис в полете, X20 – чистота на борту, X21 – задержка отправления в минутах, X22 – задержка прибытия в минутах. Выходной параметр D1 – удовлетворенность пассажира перелетом.

Входные параметры X7 – X20 представляют из себя результаты опроса пассажиров, где 0 – не применимо (например, WiFi недоступен в полете), 1 – пассажир совершенно не удовлетворен соответствующим параметром, 5 – полностью удовлетворен. Выходной параметр D1 является бинарным, где 0 – пассажир удовлетворен перелетом, 1 – нейтрально относится к полету или неудовлетворен.

Категориальные входные параметры (X1, X2, X4, X5) были преобразованы в соответствующие индикаторные параметры.

Множество данных разделено на обучающую выборку, состоящую из 103904 примеров, и тестовую выборку, состоящую из 25976 примеров.

Проектирование, обучение и тестирование модели. Проектирование, обучение и тестирование модели выполнялось на языке программирования Python с применением инструмента scikit-learn [4].

Одним из преимуществ деревьев принятия решений является автоматический отбор признаков для принятия решения в узлах [5]. Это позволяет не задумываться об отборе входных параметров, поэтому на вход модели были переданы все имеющиеся входные параметры.

При построении дерева принятия решений важным параметром является размер модели, выражающийся в количестве листьев в дереве. Для определения оптимального количества листьев использовался следующий подход: экспоненциально увеличивая количество листьев, модель обучалась на обучающей выборке, после чего измерялась ее точность (доля верно предсказанных ответов) для обучающих и тестовых выборок. Эксперименты показали (рис. 1), что после достижения размера в 256 листьев модель, достигнув максимального значения точности на тестовой выборке, начинает переобучаться.




Рис. 1. Зависимость точности предсказания на обучающем и тестовом множествах в зависимости от размера дерева принятия решений

Полученная модель с 256 листьями показала точность в 95,7% на тестовой выборке.

Поскольку в [2] использовалась лишь часть доступного множества данных, для проведения более релевантного сравнения с результатом, опубликованным в [2], дополнительно модель с той же архитектурой была обучена на четырех тысячах случайных примеров. Точность такой модели составила 91,2% на тестовой выборке при 256 листьях в дереве, но даже при двух листьях (то есть при модели, состоящей из одного разделяющего узла) точность на тестовом множестве составила 78,3%, что соответствует средней ошибке тестирования в 21,7%, что лучше, чем результат, полученный в [2].

Исследование предметной области. Для выявления наиболее значимых параметров в первую очередь были рассмотрены значения свойства `feature_importances_`, а также значение метрики `permutation_importance` для полученной модели. В инструменте `scikit-learn` значение свойства `feature_importances_` позволяет выделить параметры, узлы с которыми в качестве разделяющей переменной дают наибольший суммарный вклад в изменение критерия Джини. Значение метрики `permutation_importance` показывает важность параметра при помощи проведения следующего статистического эксперимента: фиксируется все множество данных, кроме данных, относящихся к заданному параметру, после чего заданный параметр меняется случайным образом во всех примерах, а затем измеряется, насколько это повлияло на точность модели [6].

В обеих метриках наиболее важными параметрами оказались X4 (цель поездки), X7 (WiFi в полете) и X12 (онлайн-регистрация на рейс). В [2] параметры X7 и X4 также оказались наиболее важными, однако параметр X12 стал лишь восьмым по важности, в то время как для полученного дерева принятий решений с точки зрения свойства `feature_importances_` это наиболее важный параметр.

Обратимся теперь к структуре полученного дерева. Оказалось, что узлы, ближайшие к корню дерева с 256 листьями, совпадают с узлами дерева с 6 листьями. Наиболее важными параметрами с точки зрения структуры дерева являются те, что попали в наиболее близкие к корню листья, так как они приводят к наиболее сильному расщеплению исходного множества, а эти листья совпадают для деревьев с 6 и 256 листьями.

Рассмотрим модель, обученную на описанной выше выборке, представляющую из себя дерево принятия решений, состоящее из 6 листов, структура которого изображена на рис. 2.




Рис. 2. Дерево принятия решений с шестью листьями

Из структуры дерева видно, что корневой узел разделяется за счет параметра X12 (пассажиры оценили удовлетворенность онлайн-регистрацией от 0 до 3 или от 4 до 5). Также наиболее близкие к корню узлы содержат параметры X4 и X7, что подтверждает результаты, описанные выше

Заключение. В результате исследования построена модель на основе деревьев принятия решения для прогнозирования уровня лояльности потребителя к авиакомпании.

Спроектированная модель учитывает 22 входных параметра. Методами оценки важности признаков при перестановках, влияния на критерий Джини и изучения узлов полученного дерева, выявлено, что наибольшее влияние на лояльность пассажира имеют наличие и качество WiFi на борту, цель поездки и удобство онлайн-регистрации на рейс.

Таким образом, для увеличения спроса и повышения потребительской лояльности авиакомпаниям следует уделить внимание качеству WiFi на борту воздушного судна, а также удобству процесса онлайн-регистрации.

Библиографический список

1. Коршунов Ю.М. Математические основы кибернетики. М.: Энергоатомиздат, 1987. – 296 с.
2. Богомяткова Е.А., Лобанова В.Е. Прогнозирование удовлетворенности пассажиров авиаперелетом // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века : сборник статей по материалам Седьмой всероссийской научно-практической конференции с международным участием (г. Пермь, 21-22 октября 2021 г.) / под редакцией Л.Н. Ясницкого; Пермский государственный национальный исследовательский университет. – Пермь, 2021. С. 175-180.
3. Airline Passenger Satisfaction. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com/teejmahal20/airline-passenger-satisfaction>
4. Кокорев, Д.С., Степаненко Д.Б. Scikit-learn: машинное обучение в Python // Аллея науки. – 2018. – Т. 1, № 1(17). – С. 834-838.
5. Кафтаников, И. Л. Особенности применения деревьев решений в задачах классификации / И. Л. Кафтаников, А. В. Парасич // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. – 2015. – Т. 15, № 3. – С. 26-32.
6. Шевская, Н.В. Объяснимый искусственный интеллект и методы интерпретации результатов // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, № 2(33).

THE DEVELOPMENT OF AN INNOVATIVE APPROACH TO STUDYING THE LEVEL OF CUSTOMER LOYALTY IN THE AIR TRANSPORTATION INDUSTRY USING MACHINE LEARNING

Denis S. Korotchenko

Saint Petersburg State University,
7-9 Universitetskaya Embankment, St Petersburg, Russia, 199034
korotchenkods@gmail.com

Shmidt Svetlana Andreevna

Yandex LLC,
11 bldg. 2 Timur Frunze str., Moscow, Russia, 119021
ivanovii@gmail.com

The article presents an innovative model for predicting customer loyalty to an airline. The model is based on a decision tree, which allows for more accurate forecasting than the neural network approach previously used. Additionally, the study identified key factors that affect passenger loyalty, which can be used by airlines to enhance demand and customer satisfaction.

Keywords: innovative approach, machine learning, mathematical modeling, artificial intelligence, decision tree, forecasting, consumer loyalty, airline industry.

ВЛИЯНИЕ ФИНАНСОВЫХ ПОКАЗАТЕЛЕЙ НА УСТОЙЧИВОСТЬ КОМПАНИЙ В РАЗНЫХ СТРАНАХ

Лашкевич Елизавета Витальевна

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

Исследование направлено на изучение влияния финансовых показателей на устойчивость компании. В статье представлено описание разработки универсальных прогностических моделей для оценки вероятности финансовой несостоятельности фирм в разных странах. Полученные модели позволяют с достаточно точно определять вероятность банкротства на основании финансовых параметров.

Ключевые слова: машинное обучение, финансовая устойчивость, прогнозирование вероятности банкротства.

Введение. В настоящее время известно множество моделей прогнозирования банкротств, однако их применение, как правило, ограничено одной страной. В то же время компании, выходящие на новые рынки, часто не имеют достаточных данных для построения надежной модели оценки локальных поставщиков, партнеров и других экономических агентов, действующих в конкретной стране. Одним из возможных решений в таком случае является применение для оценки фирм нового рынка моделей, обученных на данных стран, в которых заинтересованная компания давно ведет бизнес. Однако, при этом возникает вопрос переносимости таких моделей.

Исследования в области прогнозирования банкротства являются ключевым направлением в банковском деле, финансах и бухгалтерском учете уже более пятидесяти лет [1, 2]. В этой области в первую очередь рассматриваются два направления: прогнозирование корпоративного банкротства и изучение процесса банкротства. В то время как прогнозирование банкротства часто основывается на анализе финансовых показателей за короткий период до наступления кризиса, изучение процесса банкротства в течение более длительного периода времени позволяет глубже понять, как происходит банкротство предприятий [3].

Исследователи используют как качественные [4-7], так и количественные [8, 9] методы для анализа финансовых проблем. Количественные методы включают в себя статистические методы и методы машинного обучения, анализирующие финансовые коэффициенты, отзывы клиентов и другие данные для прогнозирования финансовой несостоятельности [10-17]. Эти методы включают линейные и нелинейные подходы, такие как дискриминантный анализ, деревья классификации и нейронные сети.

Хотя большинство исследований основано на данных по отдельным странам или отраслям, предпринимаются попытки оценить применимость этих мо-

делей в международном масштабе [18]. Однако из-за различий в корпоративном управлении, законодательстве и стандартах бухгалтерского учета в разных странах создание универсальной модели прогнозирования банкротства остается сложной задачей. В связи с этим возникает главный вопрос исследования: «Можно ли разработать модель прогнозирования финансовой несостоятельности, которая была бы эффективна в разных странах и условиях?» Этот вопрос находится в центре внимания текущего исследования, целью которого является изучение возможности создания такой модели.

Постановка задачи и формирование набора данных. Данные собраны из системы ORBIS (ex-Amadeus), поддерживаемой Moody's Analytics/Bureau van Dijk. Ресурс содержит исчерпывающую информацию о более чем 400 миллионах государственных и частных компаний и организаций по всему миру – 40 миллионов из этих записей содержат подробную финансовую информацию. В данном исследовании используются финансовые данные промышленных компаний за 2021 год.

Набор данных для создания моделей содержит 18 961 797 компаний. Данные содержат 286 атрибутов, содержащих различную информацию о финансовых показателях компаний, а также о виде деятельности, регионе и т.д. Также набор данных был дополнен несколькими расчетными показателями, отражающими различные аспекты финансового состояния компании, такие как ликвидность, стабильность, долговой рычаг, а также показатели модели Альтмана. В качестве целевой переменной использовался статус компании.

Основная цель данной работы – разработать модель, позволяющую точно оценить вероятность финансового краха для разных стран. Для достижения этой цели был проведен тщательный анализ финансовых данных нескольких стран. Для начала страны были разделены на две группы – развитые и развивающиеся – с использованием подхода Всемирного банка, основанного на показателе ВВП на душу населения [19]. Важно отметить, что некоторые страны, такие как Чили, Соединенные Штаты Америки и Россия, были исключены из анализа. Это объясняется тем, что финансовые системы этих стран значительно отличаются от тех, которые анализируются в данном исследовании.

Проектирование, обучение и тестирование моделей. На первом этапе был произведен однофакторный анализ (SFA) с целью выявления наиболее информативных признаков по их статистической зависимости от целевой переменной. Чтобы оценить производительность бинарной модели классификации в условиях несбалансированных данных использовались метрики точность (Precision), полнота (Precision), F1-мера (F1-score), площадь под ROC-кривой (Area under ROC-curve, AUC-ROC), доля отрицательных объектов, неправильно предсказанных положительными (false positive rate, FPR), доля положительных объектов, неправильно предсказанных отрицательными (false negative rate, FNR).

В качестве алгоритмов для экспериментальных моделей сначала использовались линейные (Logistic regression, далее – LR) и нелинейные (DecisionTree, далее – DT, RandomForest, далее – RF CatBoost, далее – CB).

На основании шорт-листа WOE¹-трансформированных признаков, полученного на этапе однофакторного анализа, затем был проведен многофакторный анализ (MFA). Окончательная комбинация признаков подбиралась итеративно с помощью логистической регрессии с параметрами по умолчанию с учетом максимизации Джини.

Для определения наиболее значимых признаков для нелинейных моделей использовались методы Feature importance и Permutation importance.

Исследование предметной области. В финальную спецификацию логистической регрессионной модели для группы развивающихся стран (далее – *LR_{developing}*) попали себестоимость проданных товаров, оборотный капитал, денежный поток, коэффициент оборачиваемости активов и чистая прибыль. Для группы развитых (далее – *LR_{developed}*) значимые финансовыми показатели – маржа прибыли, операционные денежные средства, прочие средства акционеров, период инкассации (дни), прибыль на одного сотрудника, налогообложение, коэффициент ликвидности. Фактически, для двух линейных моделей мы видим, что нет таких финансовых показателей, которые были бы значимы для всех типов стран.

Для модели CatBoostClassifier, обученной на данных стран развивающейся группы (далее – *CB_{developing}*) наиболее значимыми признаками являются операционная выручка, объем продаж, прочие средства акционеров, себестоимость проданных товаров, прибыль на одного сотрудника. обученной на данных стран развитой группы (далее – *CB_{developed}*) наиболее значимыми признаками являются прочие средства акционеров, прибыль на одного сотрудника, продажи, средства акционеров, коэффициент оборачиваемости активов.

Учитывая качество данных, результаты эксперимента и очень сильный дисбаланс классов, можно считать, что модель работает хорошо, если Gini больше 80%, F1 больше 70% и FPR меньше 30%. Таким образом, *LR_{developing}* работает неудовлетворительно на выборке для тестирования для всех стран, *LR_{developed}* работает хорошо для Австрии (Джини – 92.48%), Литвы (Джини – 94.76%) и Германии (Джини – 87.55%).

CB_{developing} помогла добиться высоких результатов для всех стран. Что касается *CB_{developed}*, то в некоторых странах, таких как Финляндия (F-мера – 45.81%), Хорватия (F-мера – 23.10%), Португалия (F-мера – 40.80%) и Латвия (F-мера – 46.43%), она показала низкие результаты. С другой стороны, модель показала удовлетворительные результаты для Франции (Джини – 76.86%, F-мера – 58.77%) и Швеции (Джини – 87.74%, F-мера – 68.35%), что является многообещающим признаком. Тем не менее, чтобы обеспечить надежность результатов, важно провести дальнейшие исследования и анализ, которые помо-

¹ WOE-преобразование (WOE-биннинг) – это метод группировки переменных в категории на основе уровня их связи с целевой переменной. Показатель веса доказательств (Weight of Evidence, WOE) рассчитывается для каждой категории переменной и зависит от процентного соотношения «хороших» и «плохих» событий в каждой группе.

гут создать более надежную и точную модель применимую ко всем странам этой группы.

С целью построения модели, которая будет эффективна для всех стран группы, дополнительно была произведена кластеризация стран по экономическим факторам. В длинный список таких факторов для кластеризации входят ВВП на душу населения, ВВП, ВНД на душу населения, уровень безработицы и индекс легкости ведения бизнеса. Результаты KMeans кластеризации приведены на рис.




Рис. Кластеризация стран (KMeans)

Для модели логистической регрессии первого кластера (далее – LR_{cl_1}) в финальную спецификацию попали оборотный капитал, денежный поток и коэффициент оборачиваемости активов (как для $LR_{developing}$); операционные денежные средства, прибыль на одного сотрудника и период инкассации (дни) (как для $LR_{developed}$); акционерные средства и коэффициент платежеспособности, можно сказать, что эти финансовые показатели являются значимыми для компаний данного кластера стран. Однако такая модель показывает результаты хуже по сравнению с $LR_{developing}$ и $LR_{developed}$.

На основе модели логистической регрессии второго кластера (далее – LR_{cl_2}) было установлено, что наиболее значимыми характеристиками для этих стран являются рентабельность собственного капитала (с использованием чистой прибыли) до налогообложения, валовая маржа, прибыль до вычета процентов и налогов и оборачиваемость чистых активов. Модель также не показала хороших результатов для большинства стран, за исключением Швеции (Джини – 96.81%, F-мера – 84.29%).

Наиболее информативными характеристиками первого кластера модели CatBoostClassifier (далее – CB_{cl_1}) являются акционерные средства, прочие акционерные средства, денежный поток, прибыль на одного сотрудника и коэффициент оборачиваемости активов, причем почти все эти характеристики входят в первую пятерку в $CB_{developed}$. Что касается второго кластера модели CatBoostClassifier (далее – CB_{cl_2}), то здесь наиболее значимыми характери-

ками являются прибыль до вычета процентов и налогов, прибыль/убыток до налогообложения, прочие фонды акционеров, базовая доходность, валовая прибыль. Данная модель также показала результаты хуже, чем $CB_{developing}$ и $CB_{developed}$.

Кроме того, чтобы выяснить, можно ли на данных одной страны разработать такую интерпретируемую модель, которая будет эффективна в другой, была разработана модель логистической регрессии для компаний Германии (далее – LR_G). Модель показывает достаточно хорошие результаты только для Австрии (Джини – 93.55%, F-мера – 87.07%) и Болгарии (Джини – 88.32%, F-мера – 72.10%).

Окончательная спецификация LR_G включает средства акционеров, операционную выручку и финансовые расходы, рентабельность активов – прибыль/убыток до налогообложения.

На практике модель логистической регрессии на данных Германии, Люксембурга, Франции, Венгрии и Швеции (далее – LR_{GLFHS}) показала свою эффективность при точной оценке поставщиков на новых рынках Австрии (Джини – 92.50%, F-мера – 85.62%), Болгарии (Джини – 95.15%, F-мера – 76.83%) и Словении (Джини – 97.39%, F-мера – 77.28%). Используя данные с аналогичных рынков, корпорации могут получить ценную информацию о потенциальной эффективности поставщиков на новом рынке. Это поможет им принимать обоснованные решения о том, с какими поставщиками работать и как управлять отношениями с ними.

Заключение. Подводя итог, можно сказать, что удалось разработать точную модель прогнозирования финансовой несостоятельности для большинства стран. Исследование подчеркивает важность тщательного тестирования и разработки при создании моделей, которые будут применяться в разных регионах. Если учесть более широкий спектр факторов и собрать больше данных из разных стран, возможно, удастся создать более эффективную модель, которую можно будет применять более широко.

Библиографический список

1. Agarwal, V., Taffler, R.J., (2007). Twenty-five years of the Taffler Z-score model: does it really have predictive ability? Account. Bus. Res. 37 (4), 285–300;
2. Grice, J.S., Dugan, M.T., (2001). The limitations of bankruptcy prediction models: some cautions for the researcher. Rev. Quant. Finan. Acc. 17 (2), 151–166;
3. Zelenkov Y.A. (2022) Analysing the firm failure process using Bayesian networks. Business informatics, 16(1):22-41;
4. O'Connor, B., Balasubramanyam, V., Miller, P. (2010). Qualitative analysis of textual data from financial reports to predict bankruptcy in the US banking industry. Journal of Business Research, 63 (9-10), 943-951;
5. Marques, A., Carvalho, J., Ferreira, M. (2013) Qualitative analysis of textual data from financial reports to predict bankruptcy in the Portuguese banking industry. International Review of Financial Analysis, 29, 1-10.
6. Li Y., Li L., Wang Z. (2015) Using qualitative analysis of textual data from financial reports to predict bankruptcy in China's stock market. Expert Systems with Applications, 42(20): 7114-7125;

7. Goh K. H., Lim K. Y. (2015) Qualitative analysis of financial statements: A review. *International Journal of Managerial Finance*, 11(2):102-130;
8. Wang Y., Wang Y., Li J. (2018) Bankruptcy Prediction in Chinese Banking Sector Based on Text Mining and Natural Language Processing. *IEEE Access*, 6, 51820-51827;
9. Kuo Y.-L., Chiang C.H., Hsu C.H. (2019) Sentiment analysis of financial reports: A review. *Expert Systems with Applications*, 115: 139–153;
10. Belloc J.L., Giacomino D.E., Akers M.D., (2007). A review of bankruptcy prediction studies: 1930 to present. *J. Financ. Educ.* 1–42;
11. Beaver W. (1996). Financial ratios as predictors of failure. *Journal of Accounting Research*, 5, 71–111.
12. Altman E. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609.
13. Fitzpatrick P., (1932). A Comparison Of Ratios Of Successful Industrial Enterprises With Those Of Failed Firms. *Certif. Public Accountant* 1 (1), 598–605;
14. Shi Y., & Li, X. (2019). An overview of bankruptcy prediction models for corporate firms: A systematic literature review. *Intangible Capital*, 15(2), 114–127;
15. Du Jardin, P. (2015). Bankruptcy prediction using terminal failure processes. *European Journal of Operational Research*, 242(1), 286–303;
16. Du Jardin P. (2011) *Survival Analysis: A Practical Approach to Analyzing Financial Risk*. Wiley;
17. Zelenkov Y., (2020) Bankruptcy Prediction Using Survival Analysis Technique. *IEEE 22nd Conference on Business Informatics (CBI)*, 141-149;
18. Altman E.I., Iwanicz-Drozdzowska M., Laitinen E. K., Suvas A. (2017) Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. *Journal of International Financial Management & Accounting*, 28(2): 131-171
19. Semak A. (2019) Economic development. Determination of the factors causing the "Great divergence." Resolving international economic problems with the tools of contemporary econometrics (K. Beck, ed.). Lazarski University Press.

THE IMPACT OF FINANCIAL PERFORMANCE ON THE SUSTAINABILITY OF COMPANIES IN DIFFERENT COUNTRIES

Elizaveta V. Lashkevich

HSE University,
Str. Myasnitskaya, 20, Moscow, Russia, 101000
evlashkevich@hse.ru

The research is aimed at studying the impact of financial indicators on the sustainability of the company. The paper describes the development of predictive models to assess the probability of financial insolvency of firms in different countries. The resulting models allow for a reasonably accurate determination of the probability of bankruptcy based on financial variables. Ultimately, this research highlights the importance of rigorous testing and development when creating models that will be applied across different regions. By taking into account a broader range of factors and gathering more data from different countries, it may be possible to create a more effective model that can be applied more broadly.

Keywords: machine learning, financial stability, bankruptcy probability prediction.

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ СТОИМОСТИ ЖИЛОЙ НЕДВИЖИМОСТИ ПЕРВИЧНОГО РЫНКА В ГОРОДЕ ПЕРМИ

Зянкина Екатерина Григорьевна

Пермский государственный национальный исследовательский университет,
614068, Россия, г. Пермь, ул. Букирева, 15,
ekaterinazyankina@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования стоимости недвижимости первичного рынка в городе Перми. Система позволяет с большой точностью предсказать стоимость недвижимости в определенный момент времени на основании данных о параметрах застройки.

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

Введение. Прогнозирование стоимости квартир на первичном рынке недвижимости является одной из актуальных и важных для изучения тем в настоящее время. Ранее были представлены работы по изучению стоимости недвижимости на вторичном рынке. Однако, в связи с увеличением объема строительства новых жилых домов в городе Пермь, нельзя точно оперировать параметрами стоимости домов, которые были построены задолго до этого. Существенная разница заключается в том, что динамика цен на квартиры в первичном рынке больше, чем на вторичном рынке недвижимости. Это связано с ключевым фактором: продажи квартир начинаются до того, как жилье будет введено в эксплуатацию, квартиры продаются на этапе строительства. С юридической точки зрения, граждане покупают не саму квартиру как существующий объект, а долю в строительстве. Такое отличие существенно влияет на образование цен на такие «доли», которые в будущем регистрируются как объекты недвижимости. И поэтому, подход, применяемый к формированию цен на жилье на вторичном рынке недвижимости не может быть полностью применен к жилью, которое еще строится в фонде первичной недвижимости.

Как показал опыт Пермской научной школы искусственного интеллекта, [1-4], правильно натренированная нейросетевая система может добиться успешности большей части прогнозов стоимости квартир на вторичном рынке недвижимости. Как показывает практика инвестирования в недвижимость [5-6], новостройки пользуются большим спросом в данном вопросе. Поэтому ставится задача: определить стоимость продажи квартир первичного рынка недвижимости на разных этапах строительства.

Данная работа поможет застройщикам более верно определить стоимость недвижимости на разных этапах строительства и изменять ее в зависимости от текущих условий, чтобы сохранить спрос граждан на участие в долевым строительстве и при этом извлечь максимальную выгоду от строительства. Инвесто-

рам– для лучшего выбора покупки доли объекта строительства и его дальнейшей продажи с извлечением максимальной прибыли. А гражданам, желающим купить квартиру для собственного проживания, понять в какой этап строительства им выгоднее вложиться в зависимости от обстоятельств.

Сбор данных происходит по объектам, строящимся или недавно введенным в эксплуатацию на территории города в данный момент времени, так как собрать данные за прошедшие года не представилось возможным. Основная цель работы –проектирование, обучение и тестирование нейросетевой модели на этих данных. Созданную нейросеть исследовать на предмет выявления закономерностей рынка вновь вводимой городской недвижимости. Конечный результат – нейросетевая система, способная прогнозировать стоимость квартир.

Постановка задачи и формирование DataSet. Для создания нейросетевой системы были выбраны следующие параметры: X1 – год ввода объекта в эксплуатацию, X2 –этап строительства, X3 –этажность застройки, X4 – материал стен, X5 –класс жилья, X6 –расстояние до центра (км), X7 –отделка квартиры, X8 –формат квартиры, X9 – этаж квартиры, X10 –площадь квартиры. Выходной параметрD1 – стоимость конкретной квартиры.

Множество примеров собрано вручную с интернет-источников: сайты Авито [7] и ДомКлик [8], официальные сайты застройщиков, сервис базы данных новостроек. Перед проектированием нейросети выполнена очистка множества от противоречивых примеров, выбросов, дубликатов путем использования программы Нейросимулятор 5[9-10]. Некорректными примерами стали те, где стоимость квартиры полностью не соответствовала реальным входным параметрами те, что относятся к элитному и частному жилью. Объем итогового множества составил 4100 примеров, которые были перемешаны и разделены на обучающее, валидирующее и тестовое множества в соотношении 70%, 20%, 10%.

Проектирование, обучение и тестирование нейросети. Проектирование, обучение, тестирование нейросети выполнялись в программе Нейросимулятор 5 по методике, указанной в учебном пособии [11].После оптимизации спроектированная нейросеть представила собой персептрон, который имеет 10 входных, 1 выходной и 1 нейрон на 1 скрытом слое.

Обучение сети производилось на основе 2870 примеров обучающего и 818 примеров валидирующего множеств. Для оценки корректной работы спроектированной сети использовалось 412 примеров тестового множества. Средняя ошибка тестирования составила 3%, что можно считать отличным результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью множествами. На гистограмме отображено 50 тестовых примеров. Из изображенных результатов можно сделать вывод об адекватной работе спроектированной нейросети.




Рис. 1. Результат тестирования нейронной сетив Нейросимулятор 5

Исследование предметной области. Оценка значимости параметров выполнена с помощью программы Нейросимулятор 5. В результате наиболее значимыми параметрами является площадь квартиры, материал стен, расстояние до центра, класс жилья (рис. 2).




Рис. 2. Значимость входных параметров нейросетевой модели

Далее проведено исследование полученных зависимостей между входными параметрами и стоимостью квартиры. Для этой цели были отобраны нейтральные примеры, про которые нейросеть не может с точностью определить, какая стоимость квартиры будет. В качестве примеров использовались следующие форматы квартир: квартира-студия, 1-комнатная, 2х-комнатная, 3х-комнатная, 4х-комнатная квартиры. В процессе анализа изменялся 1 из 10 параметров.

Как указано выше, самый значимый параметр – площадь квартиры (X10). Изменим его в пределах от 20 до 105 кв.м. Нейросеть прогнозирует увеличение стоимости квартиры пропорционально увеличению ее площади (рис. 3). Аналогичный результат был получен в ранее опубликованных исследованиях [12, 13].




Рис. 3. Зависимость стоимости квартиры от ее площади

Второй значимый параметр – материал стен(X4). Нейросеть прогнозирует стоимость квартир в монолитном доме выше, чем в панельном (рис. 4).




Рис. 4. Зависимость стоимости квартиры от материала стен

Третий по значимости параметр – расстояние квартиры до центра города (X6). Изменим его в пределах от 0 до 25 км. Нейросеть спрогнозировала, что чем ближе дом расположен к центру города, тем квартиры в нем дороже (рис. 5).




Рис. 5. Зависимость стоимости квартиры от расстояния до центра

Четвертый по значимости параметр – класс жилья (X5). Нейросеть сделала прогноз: чем выше класс жилья, тем стоимость квартир в нем дороже (рис. 6).

Заключение. В результате исследования построена система нейросетевого прогнозирования стоимости недвижимости на первичном рынке жилья в городе Пермь. Система спроектирована в программе «Нейросимулятор 5». Была произведена попытка спроектировать аналогичную нейросеть на языке программирования Python с использованием библиотеки Keros. Однако данная попытка не увенчалась успехом.

Спроектированная нейросетевая модель учитывает 10 входных параметров. Методом сценарного прогнозирования построены графики зависимостей прогнозируемой стоимости конкретной квартиры от изменения входных параметров. Продемонстрированы графики зависимостей наиболее влияющих на стоимость квартиры параметров, таких как площадь квартиры, материал стен, расстояние до центра города, класс жилья. Остальные параметры имеют минимальное в сравнении с вышеуказанными параметрами и почти одинаковое влияние на стоимость квартиры.




Рис. 6. Зависимость стоимости квартиры от класса жилья

Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать стоимость квартиры в строящихся и только что сданных в эксплуатацию домах. Набор параметров может быть изменен для прогнозирования стоимости недвижимости на вторичном рынке жилья.

Исходя из исследования итоговых результатов, система работает корректно и может в полной мере использоваться застройщиками и покупателями в целях прогнозирования стоимости недвижимости в определенный промежуток времени для планирования продажи или покупки квартир в строящихся домах.

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. Сер. «Экономика» = Perm University Herald. Economy. 2016. № 2(29). С. 54–69. doi: 10.17072/1994–9960–2016–2–54–69.
2. Ясницкий, Л.Н. Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости жилых объектов на примере рынков недвижимости Екатеринбурга и Перми [Текст] / Л.Н. Ясницкий, В.Л. Ясницкий // Имущественные отношения в Российской Федерации. – 2017. – № 3 (186). – С. 68–84 (1,06 п. л.).

3. Ясницкий В.Л., Алексеев А.О., Ясницкий Л.Н. Массовая оценка и сценарное прогнозирование рыночной стоимости городской недвижимости на основе технологии нейросетевого моделирования: монография. – Москва: РУСАЙНС, 2019. – 112 с.
4. Ясницкий, В.Л. Нейросетевое моделирование в задаче массовой оценки жилой недвижимости города Перми [Текст] / В.Л. Ясницкий // Фундаментальные исследования. – 2015. – № 10–3. – С. 650–653 (0,25 п. л.).
5. Blog.domclick.ru – Инвестиции в недвижимость: как выгодно вложить деньги. [Электронный ресурс]. Режим доступа: <https://blog.domclick.ru/post/investiczii-v-nedvizhimost-kak-vygodno-vlozhit-dengi>
6. Realty.rbc.ru – Вторичка VS новостройка: во что выгоднее инвестировать. [Электронный ресурс]. Режим доступа: <https://realty.rbc.ru/>
7. Avito.ru – Недвижимость в Перми. [Электронный ресурс]. Режим доступа: <https://www.avito.ru/perm/nedvizhimost>
8. Perm.domclick.ru – Сервис по подбору недвижимости. [Электронный ресурс]. Режим доступа: <https://perm.domclick.ru/?from=topline2020>
9. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RU2014612546. Заявка № 2014610341 от 15.01.2014.
10. 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.
11. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
12. 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. Vol. 2021, Article ID 5392170, 17 pages. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1155/2021/5392170>
13. Yasnitsky L.N., Yasnitsky V.L. Technique of design for integrated economic and mathematical model for mass appraisal of real estate property. Study case of yekaterinburg housing market. Journal of Applied Economic Sciences. 2016. T. 11. № 8. С. 1519-1530.

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

Ekaterina G. Ziankina

Perm State National Research University
Bukireva str., 15, Perm, Russia, 614068
ekaterinazyankina@gmail.com

Perm has a good popularity among people. Local and federal developers plan new projects every year. The number of new buildings in Perm city is growing. The article describes the development of a neural network system for predicting the value of real estate on the primary market in Perm city. The system allows you to predict the value of primary real estate at a certain time based on data of building's parameters. We have collected a data set of 4100 examples. Designing, training, and testing of the neural network were carried out using the program "Neurostimulator 5". The system is a multilayer perceptron. We collected 412 examples and tested the system. The middle testing error was 1.4%. We got a great result. We used the scenario forecasting method and created graphics of the dependence the value of a special apartment on 11 input parameters. We were able to predict the value of an apartment in new buildings with high accuracy. The end result was a neural network system that predicts the value of apartments at different stages of building.

Keywords: artificial intelligence, neural network technologies, forecasting, urban real estate, primary real estate market, forecasting the value of real estate.

ТЕНЗОРНЫЕ БАНДИТЫ И ИХ ПРИЛОЖЕНИЯ

Горбач Марина Павловна

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

Алгоритмы многоруких бандитов являются мощным теоретическим аппаратом, который позволяет эффективно решать множество практических задач, таких как задачи рекомендательных систем и динамического ценообразования. При этом множество существующих алгоритмов страдает от так называемого “проклятья размерности” – оценки сложности алгоритма в лучшем случае зависят линейно от количества действий (ручек), которых может быть очень много. Для того, чтобы преодолеть эту теоретическую проблему, недавно была предложена парадигма низкоранговых тензорных бандитов, основанная на предположении о низком ранге у тензора ожидаемых наград. В рамках статьи этот подход был обобщён на разложение в тензорный поезд, а также было исследовано поведение алгоритмов в контекстуальной постановке задачи.

Ключевые слова: Алгоритм многоруких бандитов, низкоранговые приближения, разложение Таккера, тензорный поезд, тензорные вычисления.

Введение. В современном мире принятие решений в условиях неопределённости становится всё более важной и трудоёмкой задачей, так как пространство выбора, как и объёмы данных, постоянно растёт. Соответственно, большинство ранее распространённых способов, таких как коллаборативная фильтрация, стали непригодными к использованию. Одним из способов решения таких задач являются алгоритмы многоруких бандитов.

Алгоритмы многоруких бандитов – алгоритмы, в которых агенту необходимо сделать выбор, где каждый вариант представлен ручкой. При выборе каждая из ручек возвращает некоторую награду, максимизировать которую – цель агента. В данной статье речь пойдёт о тензорном представлении алгоритмов такого типа.

Данная работа представляет новый алгоритм на основе разложения в тензорный поезд, а также реализует его экспериментальное сравнение с уже существующими алгоритмами TensorElimination, EpochGreedy и Ensemble Sampling [9], основанными на разложении Таккера.

Исследование предметной области.

Тензорные разложения. В существующих до этого алгоритмах тензорных многоруких бандитов использовалось разложение Таккера [8]. Данная статья описывает алгоритм, основывающийся на разложении в тензорный поезд [6]. Важно отметить, что многие операции, необходимые для итерации алгоритмов многоруких бандитов, например поиск максимального элемента в тензоре и сложение двух тензоров, могут быть реализованы эффективно для такой структуры [2], [3].

Многорукые бандиты. В последнее время алгоритмы многоруких бандитов развивались достаточно активно [5], [7]. Один из наиболее популярных на данный момент алгоритмов в силу своих хороших результатов – алгоритм верхних доверительных границ [1]. В этом алгоритме решения принимаются исходя из принципа Оптимизма перед лицом неопределенности [5]. Он утверждает, что выбор должен делаться исходя из предположения, что среда будет настолько выгодной агенту, насколько это возможно.

Контекстуальные многорукие бандиты. Алгоритмы многоруких бандитов, которые описаны выше, обучаются исключительно на данных получаемых из общения со средой, которые представлены величинами наград. Однако, в реальности обычно существует некая дополнительная информация о среде, которую агент не может учесть таким образом, однако, она может быть полезна. Алгоритмы контекстуальных бандитов учитывают такую информацию [5]. Чаще всего это нужно для рекомендательных систем, где у контекста есть несколько различных признаков, например, возраст и пол пользователя.

Тензорные бандиты. Одним из способов задать контекст в задаче многоруких бандитов является тензор. Каждая ручка задаётся в виде набора значений признаков, который позже представляется в тензорном виде. Для работы с тензорными бандитами были представлены следующие алгоритмы [18, 12, 17]. Наилучшей оценкой на потери среди представленных алгоритмов обладает *tensor elimination*.

TensorElimination. Рассмотрим один из наиболее эффективных алгоритмов, использующих низкоранговые разложения – *TensorElimination*, описанного в [9].

В алгоритмах многоруких бандитов некоторое количество первых шагов делается для получения информации о среде – фаза исследования. После этого считается средняя награда по каждой ручке, а далее выполняется операция дополнения тензора, так как некоторые ручки могли быть не использованы – это первая оценка тензора наград.

После этого запускается основной алгоритм. Каждые k (параметр алгоритма) шагов происходит обновление полученного разложения Таккера и всех вытекающих. После чего на её основе вычисляется ожидаемая награда, которая влияет на удаление или же сохранение ручки в множестве активных. Между этими обновлениями, каждый раз выбирается ручка, оценка дисперсии у которой максимальна. Авторы алгоритма приводят в [9] оценку регрета: $\mathcal{O}(p^{n/2} + p^{(n-1)/2} T^{1/2})$, где $p = \max(p_1, p_2, \dots, p_n)$. Это делает его одним из наименее зависимых от роста размерности алгоритмов, как и одним из наиболее эффективных.

EpochGreedy. Далее рассмотрим *EpochGreedy*, который представляет собой жадный алгоритм, действующий на основе низкоранговой оценки тензора наград с помощью разложения Таккера. Как и *TensorElimination*, данный алгоритм начинается с фазы исследования среды, во время которой формируется тензор из средних наград, которую сменяет жадный алгоритм. На каждом шаге строится низкоранговая оценка тензора наград с помощью разложения Таккера,

максимальное значение в которой позволяет выбрать оптимальную ручку для текущего хода.

Согласно [9] регрет данного алгоритма можно оценить как $\mathcal{O}(p^{n/2} + p^{(n+1)/3}T^{2/3})$, где $p = \max(p_1, p_2, \dots, p_n)$.

Vectorized UCB. Далее речь пойдёт о алгоритме, который является одним из наиболее популярных для решения задачи многорукого бандита в одномерном случае – об алгоритме верхних доверительных границ [1]. Как уже упоминалось ранее, использовать его эффективно для задачи тензорного бандита пока не удавалось, однако, существует подход, позволяющий его применить. Для этого нужно привести тензорную задачу к одномерной, представив тензор $X \in \mathbb{R}^{p_1 \times \dots \times p_n}$ в виде вектора $Y \in \mathbb{R}^{p_1 \cdot \dots \cdot p_n}$. После применения этой операции к изначальным данным классический алгоритм верхних доверительных границ может быть запущен.

Согласно [9] регрет данного алгоритма оценивается как $\mathcal{O}(p^n + p^{(n)/2}T^{1/2})$, где $p = \max(p_1, p_2, \dots, p_n)$. То есть, данный алгоритм действительно демонстрирует результаты хуже, чем тензорные алгоритмы.

TensorTrainAlgorithm.

Algorithm 4 TensorTrain Algorithm

```

1: input: dimensions  $\in \mathbb{N}^n$  - размерность тензора наград, ranks  $\in \mathbb{N}^n$  - размерность для
   разложения в тензорный поезд,  $T$  - общее число шагов,  $T_e$  - число шагов для исследования
   среды
2: for  $t$  in range( $T_e$ ) do                                     ▷ Фаза исследования среды
3:   Выбор произвольной ручки
4:   Обновление тензора усреднённых наград
5: end for
6: Операция дополнения тензора усреднённых наград
7: Разложение тензора усреднённых наград в тензорный поезд
8: for  $t$  in range( $T_e, T$ ) do                                     ▷ Фаза эксплуатации
9:   Выбор оптимальной ручки путём нахождения максимума текущей оценки вектора
   наград с помощью алгоритма optima_tt_max, описанного в [3]
10:  Обновление оценки тензора наград
11:  if  $t \% \text{update-each} == 0$  then
12:    Восстановление тензора наград из разложения
13:    Операция дополнения тензора усреднённых наград
14:    Разложение тензора усреднённых наград в тензорный поезд
15:  end if
16: end for

```

Теперь перейдём непосредственно к описанию разработанного алгоритма, основанного на разложении в тензорный поезд. Рассмотрим подробнее реализацию TensorTrain алгоритма. Как и в ранее описанных алгоритмах, он начинается с фазы сбора информации о среде, во время которой формирует тензор усреднённых наград, после чего выполняет для него операцию дополнения тензора [4]. Далее полученный тензор с информацией о среде раскладывается в тензорный поезд. Здесь начинается основная фаза алгоритма. На каждом шаге встаёт вопрос поиска оптимальной ручки, что делается с помощью алгоритма `optima_tt_max` [2]. Далее, после того, как была сыграна ручка, наступает момент обновления разложения. Для этого используется формула модификации ядер при сложении двух тензорных поездов (тензор награды для конкретной ручки также раскладывается в тензорный поезд).

Сложность каждого шага алгоритма будет равна: $O(nR^2P)$. Тогда сложность всего алгоритма $O(nTR^2P)$. Посмотрим на результаты тестирования при различных тензорах наград на графиках (рис.1).




Рис. 1. 5 запусков на сгенерированных тензорах наград размера $5 \times 5 \times 5$

Контекстуальные бандиты. Ранее было предложено множество вариантов решения задачи тензорных бандитов, однако при построении рекомендательной системы часто есть дополнительные данные, которые касаются каждого варианта, так называемый контекст, который подобные алгоритмы никак не учитывают. Для таких случаев используются контекстуальные бандиты. Такую задачу можно представить и как тензорную, для этого нужно добавить в тензор наград дополнительные размерности, которые будут кодировать контекст. В общем виде алгоритм будет выглядеть следующим образом. Сначала алгоритм получает контекст, выбирает часть тензора наград, соответствующую ему, и выбирает оптимальную ручку с помощью некоторого тензорного алгоритма. Один из популярных контекстуальных алгоритмов – Ensemble Sampling, предложенный в [9]. Свою идею он наследует от алгоритма Томпсона сэмплирования, а также использует разложение Таккера, как и прочие алгоритмы из [9]. В ходе исследования был реализован данный алгоритм, а также разработаны контекстуальные версии алгоритмов, описанных выше. На графике (рис. 2) отображено сравнение алгоритмов на достаточно большой размерности.




Рис. 2. 5 запусков на тензорах наград $10 \times 10 \times 10$, где первая размерность соответствовала контексту

Заключение. В данной статье были исследованы, реализованы и протестированы различные ранее известные алгоритмы для решения задачи тензорного многорукого бандита. Полученная реализация алгоритмов поддерживает произвольные размерности тензоров. Следующим шагом было создание нового

алгоритма TensorTrain для решения подобной задачи с помощью низкорангового разложения в тензорный поезд. По результатам экспериментов, этот алгоритм показал себя как один из наиболее быстрых среди существующих, в то время как по качеству он уступает некоторым, в том числе алгоритму TensorElimination.

На данный момент наиболее перспективным направлением, где используются подобные алгоритмы, являются рекомендательные системы, в которых обычно доступны дополнительные данные о каждой из ручек. Поэтому следующим шагом работы было исследование контекстуальных бандитов. Были реализованы уже известные алгоритмы для произвольной размерности, а также произведено обобщение алгоритма TensorTrain для контекстуального случая.

Библиографический список

1. Peter Auer, Nicolo Cesa-Bianchi и Paul Fischer. "Finite-time analysis of the multiarmed bandit problem". В: Machine learning 47 (2002), с. 235–256.
2. Andrei Chertkov, Gleb Ryzhakov, Georgii Novikov и Ivan Oseledets. "Optimization of functions given in the tensor train format". В: arXiv preprint arXiv:2209.14808 (2022).
3. Peter Georg. "Tensor Train Decomposition for solving high-dimensional Mutual Hazard Networks". Дис. . . . док. 2022.
4. Olga Klopp. "Noisy low-rank matrix completion with general sampling distribution". В: (2014).
5. Tor Lattimore и Csaba Szepesvári. Bandit algorithms. Cambridge University Press, 2020.
6. Ivan V Oseledets. "Tensor-train decomposition". В: SIAM Journal on Scientific Computing 33.5 (2011), с. 2295–2317.
7. Aleksandrs Slivkins и др. "Introduction to multi-armed bandits". В: Foundations and Trends® in Machine Learning 12.1-2 (2019), с. 1–286.
8. L. R. Tucker. "Implications of factor analysis of three-way matrices for measurement of change". В: Problems in measuring change. Подред. C. W. Harris. Madison WI: University of Wisconsin Press, 1963, с. 122–137.
9. Jie Zhou, Botao Hao, Zheng Wen, Jingfei Zhang и Will Wei Sun. "Stochastic Low-rank Tensor Bandits for Multi-dimensional Online Decision Making". В: arXiv preprint arXiv:2007.15788 (2020).

TENSOR BANDITS AND THEIR APPLICATIONS

Horbach Maryna Paulauna

HSE University,

109028, Russia, Moscow, Pokrovsky Boulevard, 11

mpgorbach@edu.hse.ru

The multi-armed bandit algorithms represent a powerful theoretical framework that enables effective solutions to a wide range of practical problems, such as recommendation systems and dynamic pricing. However, many existing algorithms suffer from the so-called "curse of dimensionality" – where the complexity estimates of the algorithm depend, at best, linearly on the number of actions (arms), which can be extremely large. To overcome this theoretical challenge, the paradigm of low-rank tensor bandits was recently proposed, based on the assumption of a low rank of the expected rewards tensor. In this paper, this approach is extended to tensor-train decomposition, and the behavior in the contextual setting was researched.

Keywords: Multi-armed bandit algorithm, low-rank approximations, Tucker decomposition, tensor train, tensor computations.

ПРИМЕНЕНИЕ МОДЕЛИ CHATGPT В ФИНАНСОВОЙ СФЕРЕ И СРАВНЕНИЕ ЕЕ РЕКОМЕНДАЦИЙ С РЕКОМЕНДАЦИЯМИ РОБОЭДВАЙЗИНГОВЫХ СЕРВИСОВ

Лаврентьева Ольга Николаевна

Московский государственный университет имени М.В.Ломоносова,
119991, г.Москва, Ленинские горы, дом 1, строение 46
onlavrentieva@gmail.com

В статье демонстрируются перспективы и основные проблемы использования ChatGPT в финансовой сфере на основании изученных англоязычных работ. Также описывается проведенное автором сравнение рекомендации робоэдвайзинговых сервисов российских финансовых компаний и ChatGPT для трех модельных инвесторов с различным уровнем приемлемого риска. Результаты показывают, что ChatGPT имеет значительный по улучшению сферы финансовых консультаций и информирования инвесторов.

Ключевые слова: ChatGPT, робоэдвайзинг, инвестиционный портфель, финансовое консультирование, искусственный интеллект.

Введение. Менее чем за два года после своего выхода в конце 2022 года ChatGPT, большая языковая модель от компании OpenAI, использующая искусственный интеллект для обработки естественного языка, нашла широкое применение в финансовой сфере, что отражается в бурно растущей научной литературе на эту тему на английском языке. В отдельных сферах и отдельных компаниях она уже меняет привычные бизнес-процессы, где-то изменения только намечаются. Исследователи отмечают значительный потенциал использования ChatGPT для анализа финансовых данных, прогнозирования рыночных тенденций и поддержки принятия инвестиционных решений.

На российском финансовом рынке пока мало свидетельств использования больших языковых моделей (по крайней мере пока отсутствует литература на эту тему), поэтому изучение опыта других стран может оказаться весьма полезным. В качестве примера можно привести сравнение рекомендаций, полученных от ChatGPT и от робоэдвайзинговых сервисов, в ходе которого можно попробовать оценить, насколько велика ценность получаемых клиентом рекомендаций в рамках этих сервисов.

Задачами этой работы является, во-первых, показать возможности применения ChatGPT в различных областях финансов, а также связанные с этим риски (этому посвящены части 1 и 2), а, во-вторых, сравнить рекомендации ChatGPT и российских робоэдвайзинговых сервисов (часть 3).

1. Области применения ChatGPT в финансах. Проведенный анализ литературы¹ позволил выделить следующие направления использования модели ChatGPT и ее предшественниц в финансовой сфере.

Анализ настроений и прогнозирование движения рынка

ChatGPT может эффективно классифицировать финансовые тексты и определять настроения рынка. [1-4] показывают, что анализ настроений инве-

сторгов с помощью ChatGPT может успешно прогнозировать доходность акций, а [5] исследовали способность GPT-4 прогнозировать будущие доходы компаний (правда, прогнозы модели имеют большую ошибку прогноза, чем консенсус-прогнозы аналитиков). [6] также обнаружили, что ChatGPT может помочь в выборе акций.

Персонализированные инвестиционные рекомендации

ChatGPT может использоваться для предоставления персонализированных инвестиционных рекомендаций на основе оценки инвестиционного профиля [2]. [7] показали, что ChatGPT может быть полезен при формировании диверсифицированных инвестиционных портфелей. [8] сравнили рекомендации ChatGPT по составлению портфеля с рекомендациями 17 робоэдвайзинговых сервисов и обнаружили, что ChatGPT предлагает подходящие портфели для инвесторов с различной степенью неприятия риска. Авторы [9] демонстрируют, как ChatGPT может генерировать объяснения различных инвестиционных концепций и стратегий в зависимости от уровня финансовой грамотности пользователя.

Анализ финансовой отчетности и новостей

ChatGPT может быть применена для быстрого анализа большого объема финансовой информации. Так, авторы [10] использовали GPT-3.5-turbo для анализа информации, представленной в годовых отчетах компаний и транскриптов их телефонных конференций для инвесторов, а авторы [11] – для извлечения из документов компании ожиданий менеджмента относительно корпоративных политик. [12] описывают кейс крупной международной компании, внедрившей ChatGPT в свои процессы внутреннего аудита

Управление рисками

ChatGPT может использоваться для улучшения процессов управления рисками в финансовых организациях [13-15], для выявления и оценки различных видов финансовых рисков, анализа сценариев развития рисковых ситуаций, помощи в принятии решений по управлению рисками.

Автоматизация клиентского обслуживания

ChatGPT может применяться для автоматизации обслуживания клиентов финансовых организаций, отвечая на типовые вопросы и предоставляя базовые консультации. По данным опроса SmartAsset, 27% финансовых консультантов уже используют или изучают возможности ChatGPT в своей работе [16].

Демократизация доступа к финансовой экспертизе

Авторы [16] провели исследование, в котором смоделировали 21 ситуацию, связанную с личными финансами, и проанализировали ответы ChatGPT. Результаты показали, что ChatGPT способен давать полезные рекомендации по широкому кругу вопросов, включая управление долгами, сбережения, инвестиции и планирование выхода на пенсию. В [17-18] отмечается, что ChatGPT способен интерпретировать результаты сложных финансовых моделей и объяснять их простым языком. Как показано в [9], ChatGPT способен генерировать тексты в стиле различных финансовых изданий, что открывает возможности для ускорения и удешевления процесса подготовки финансовой аналитики и отчетности.

Несмотря на многообещающее исследования, применение ChatGPT в финансовой сфере находится на ранней стадии и сопряжено с рядом проблем.

2. Проблемы и сложности применения ChatGPT в финансах.

Достоверность данных и надежность прогнозов

Одной из ключевых проблем является зависимость качества работы ChatGPT от данных, на которых она обучена [13]. Это ограничивает его способность давать рекомендации, основанные на текущей рыночной ситуации или последних изменениях в финансовом законодательстве. Важной проблемой также являются возможные «галлюцинации» модели, когда ChatGPT генерирует правдоподобные, но фактически неверные ответы [18].

Риск неправильных рекомендаций

ChatGPT может давать неточные или ошибочные инвестиционные рекомендации из-за ограниченности в понимании контекста [19]. Рекомендации ChatGPT имеют тенденцию быть излишне общими [16]. Еще одним источником ошибок в рекомендациях ChatGPT может являться сложность финансовых модели, которые она должна интерпретировать [17].

Ограниченные возможности анализа эмоций

ChatGPT может испытывать трудности с пониманием эмоций и психологических состояний инвесторов, что важно для принятия инвестиционных решений. Способность модели генерировать ответы на естественном языке, может привести к вводящим в заблуждение результатам [13].

Этические вопросы и ответственность

Использование ChatGPT в финансовой сфере поднимает важные этические вопросы и проблемы ответственности за выдаваемые не всегда корректные рекомендации [13]. Кроме того, привлечение модели для детальных консультаций по персональным финансовым вопросам поднимает ряд этических и правовых вопросов, связанных с защитой персональных данных клиентов.

Регуляторные ограничения и безопасность данных

В общем и целом, применение моделей искусственного интеллекта в финансовой сфере может вызывать озабоченность регулирующих органов как в связи с обозначенными выше проблемами, так и в связи с безопасностью и конфиденциальностью данных [13].

Хотя для полной реализации потенциала ChatGPT в финансовой сфере необходимо решить ряд технических, этических и регуляторных проблем, можно ожидать, что в ближайшие годы применение ChatGPT и подобных моделей в финансах будет расширяться, открывая новые возможности для инноваций и повышения эффективности финансовых процессов, повышения финансовой грамотности населения через интерактивное обучение и развитие новых подходов к объяснению инвестиционных решений.

3. Сравнение рекомендаций ChatGPT и российских робоэдвайзинговых сервисов. Одна из интересных недавних работ, исследующих возможности ChatGPT для повышения качества финансовых услуг для розничных инвесторов, сравнивала рекомендации 17 общедоступных робоэдвайзинговых сервисов и ChatGPT [8]. Эта статья послужила методологической основой для сравнения, проведенного в данной работе, а его выводы подтвердились на российском рынке.

Для сравнения рекомендаций ChatGPT с российскими робоэдвайзинговыми сервисами были созданы три модельных профиля инвесторов с разным

уровнем допустимого риска: 5%, 15% и 35%. Эти профили основываются на методиках, используемых российскими брокерами и включающих такие параметры, как возраст, доходы, финансовые цели и опыт инвестирования. Для модельных профилей были получены рекомендации от ChatGPT и российских робоэдвайзинговых сервисов. В ходе предварительного исследования автором были проанализированы 13 российских робоэдвайзинговых сервисов, рекомендации 4 из которых вошли в итоговый анализ (отсекались сервисы, не предназначенные для розничного неквалифицированного инвестора и не имеющих в открытом доступе методики определения инвестиционного профиля). Рекомендации ChatGPT и робоэдвайзинговых сервисов сравнивались по составу портфелей и величине ожидаемой доходности.

Основные выводы сравнения заключаются в следующем. Портфели, предлагаемые ChatGPT, более диверсифицированы и больше соответствуют «классической» структуре портфеля (соотношение акций и облигаций 60/40, 40/60, 20/80 для разных уровней риска). ChatGPT рекомендует большую долю вложений в акции для инвесторов с низким и средним уровнем риска – для инвестора с приемлемым риском 5% ChatGPT рекомендует 20% в акциях, в то время как некоторые робоэдвайзинговые сервисы предлагают только облигации. Для инвесторов со средним и высоким уровнем риска ChatGPT предлагает менее рискованные портфели – для инвестора с приемлемым риском 35% ChatGPT рекомендует 50% в акциях, в то время как некоторые робоэдвайзинговые сервисы предлагают 100% вложений в акции. Ожидаемая доходность, указываемая ChatGPT, в среднем ниже, чем у робоэдвайзинговых сервисов – для инвестора с высоким уровнем риска ChatGPT прогнозирует доходность 12-15% годовых, а робоэдвайзинговые сервисы робоэдвайзинговыми сервисы – в среднем 24,6%. Ответы ChatGPT содержат более подробные объяснения и обоснования рекомендаций.

В целом, ChatGPT может служить хорошим источником «второго мнения» для проверки рекомендаций финансовых советников или робоэдвайзинговых сервисов, а следовательно, использование подобных моделей способно улучшить качество финансовых консультаций и информирования инвесторов (особенно неквалифицированных).

Заключение. Несмотря на существующие ограничения, перспективы применения ChatGPT в финансовой сфере выглядят многообещающими. Возможным направлением развития применения таких моделей в финансах является разработка специализированных моделей, обученных на финансовых данных и учитывающих специфику финансовой отрасли, также создание и использование гибридных систем, сочетающих возможности AI с экспертизой человека-консультанта. Безусловно в недалеком будущем станет актуальной задача разработки нормативно-правовой базы для регулирования использования AI в финансовом консультировании.

Библиографический список

1. Bond, S. A., Klok, H., & Zhu, M. (2023). Large language models and financial market sentiment. Available at SSRN 4584928.
2. Fatouros, G., Soldatos, J., Kouroumali, K., Makridis, G., & Kyriazis, D. (2023). Transforming sentiment analysis in the financial domain with ChatGPT. *Machine Learning with Applications*, 14, 100508.

3. Lopez-Lira, A., & Tang, Y. (2023). Can chatgpt forecast stock price movements? return predictability and large language models. arXiv preprint arXiv:2304.07619
4. Ma, F., Lyu, Z., & Li, H. (2024). Can ChatGPT predict Chinese equity premiums?. Finance Research Letters, 105631.
5. Li, E. X., Tu, Z., & Zhou, D. (2024). Moneyball: GPT's Playbook for Earnings Forecasts. Available at SSRN 4480947.
6. Pelster, M., & Val, J. (2024). Can ChatGPT assist in picking stocks?. Finance Research Letters, 59, 104786.
7. Ko, H., & Lee, J. (2024). Can ChatGPT improve investment decisions? From a portfolio management perspective. Finance Research Letters, 64, 105433.
8. Oehler, A., & Horn, M. (2024). Does ChatGPT provide better advice than robo-advisors?. Finance Research Letters, 60, 104898.
9. Romanko, O., Narayan, A., & Kwon, R. H. (2023). ChatGPT-based investment portfolio selection. In Operations Research Forum (Vol. 4, No. 4, p. 91). Cham: Springer International Publishing.
10. Kim, A., Muhn, M., & Nikolaev, V. V. (2024). Bloated disclosures: can ChatGPT help investors process information?. Chicago Booth Research Paper, (23-07), 2023-59.
11. Jha, M., Qian, J., Weber, M., & Yang, B. (2024). ChatGPT and corporate policies (No. w32161). National Bureau of Economic Research.
12. Emmett, S. A., Eulerich, M., Lipinski, E., Prien, N., & Wood, D. A. (2023). Leveraging ChatGPT for enhancing the internal audit process—A real-world example from a large multinational company. Available at SSRN 4514238.
13. Gürsoy, S., & Doğan, M. (2023). Examining The Use of ChatGPT in Financial Markets with Swot Analysis. TroyAcademy, 8(3), 296-305.
14. Arnone, G. (2024). AI and Chatbots in FinTech: Revolutionizing Digital Experiences and Predictive Analytics. Springer Nature.
15. Kim, A., Muhn, M., & Nikolaev, V. (2023). From transcripts to insights: Uncovering corporate risks using generative ai. arXiv preprint arXiv:2310.17721.
16. Schlosky, M. T. T., Karadas, S., & Raskie, S. (2024). ChatGPT, Help! I Am in Financial Trouble. Journal of Risk and Financial Management, 17(6), 241.
17. Yue, T., Au, D., Au, C. C., & Iu, K. Y. (2023). Democratizing financial knowledge with ChatGPT by OpenAI: Unleashing the Power of Technology. Available at SSRN 4346152.
18. Wenzlaff, K., & Spaeth, S. (2022). Smarter than Humans? Validating how OpenAI's ChatGPT model explains Crowdfunding, Alternative Finance and Community Finance. Available at SSRN 4302443.
19. Kim, T., Park, Y., & Kim, W. (2022). The impact of artificial intelligence on firm performance. In 2022 Portland International Conference on Management of Engineering and Technology (PICMET) (pp. 1-10). IEEE.

APPLICATION OF THE CHATGPT MODEL IN FINANCE AND COMPARISON OF ITS RECOMMENDATIONS WITH THOSE OF ROBO-ADVICE SERVICES

Olga N. Lavrentieva

Lomonosov Moscow State University,
Leninskie Gory, 1, building 46, Moscow, Russia, 119991
onlavrentieva@gmail.com

The article demonstrates the prospects and main problems of using ChatGPT in finance based on the studied English-language works. It also describes the author's comparison of recommendations of robo-advisory services of Russian financial companies and ChatGPT for three model investors with different levels of acceptable risk. The results show that ChatGPT has significant potential to improve financial advice and investor information.

Keywords: ChatGPT, robo-advising, investment portfolio, financial consulting, artificial intelligence.

ПЕРСОНАЛИЗАЦИЯ ПОТРЕБИТЕЛЬСКОГО ОПЫТА С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Зеленко Мария Андреевна, Солушко Арина Сергеевна

Белорусский государственный университет
«Институт бизнеса» в Минске,
614070, Беларусь, г. Минск, ул. Обойная, 7
maria.zelenko.sb@gmail.com, arina.solushko.sb@gmail.com

В статье рассматривается персонализация потребительского опыта в качестве ключевого аспекта успешного бизнеса в условиях цифровой трансформации. Искусственный интеллект (ИИ) играет центральную роль в создании персонализированного опыта, анализируя поведение клиентов для улучшения покупок и роста бизнеса. ИИ повышает релевантность контента, лояльность клиентов и эффективность маркетинга.

Ключевые слова: Персонализация, искусственный интеллект, конфиденциальность данных, анализ потребительского поведения, маркетинговые стратегии, рекламные технологии.

Введение. Персонализация потребительского опыта является одной из актуальных тем в маркетинге. Потребительское поведение никогда не было более важным, чем сегодня. В век цифровой трансформации достичь успеха может помочь искусственный интеллект. Использование искусственного интеллекта для анализа поведения клиентов способствует росту бизнеса электронной коммерции и улучшает качество покупок. В современных условиях, когда рынок чрезвычайно конкурентоспособен и информация легко доступна, индивидуальный подход представляет собой отличную возможность привлечь и удержать аудиторию.

Потребительский ИИ – это использование методов и технологий ИИ для создания персонализированного и удобного пользовательского опыта для потребителей на разных платформах и устройствах.

Персонализация потребительского опыта с использованием искусственного интеллекта становится все более важной в свете растущих ожиданий клиентов относительно индивидуального подхода, усиления конкуренции на рынках и необходимости более эффективного анализа данных для улучшения взаимодействия с клиентами. Искусственный интеллект позволяет компаниям предлагать соответствующие продукты и услуги, что способствует повышению уровня удовлетворенности и лояльности клиентов. Это, в свою очередь, становится решающим фактором для успешного ведения бизнеса.

Искусственный интеллект как ключевой инструмент для создания уникального клиентского опыта имеет следующие предназначения:

- повышение релевантности материала: персонализация позволяет компаниям показывать клиентам тот контент, который вызывает у них интерес;
- улучшение потребительского опыта: персонифицированные предложения и пожелания способствуют более легкой и приятной связи с брендом;

- повышение лояльности клиентов: когда компания узнает и удовлетворяет требования своих потребителей, она завоевывает их лояльность;
- повышение эффективности маркетинговых инициатив: адаптированные рекламные кампании с большей вероятностью продемонстрируют повышенный уровень конверсии [1].

Персонализация опыта клиентов показывает, что компания берет во внимание их предпочтения и интересы. Это повышает вероятность того, что они будут сотрудничать с брендом.

Искусственный интеллект эффективно анализирует большие объемы данных, что дает возможность даже самым опытным аналитикам выявлять закономерности в поведении клиентов и глубже понимать их потребности. Исползованные данные помогают ИИ спрогнозировать будущее поведение клиентов. Это позволяет компаниям оперативно реагировать на возникающие проблемы, предлагать актуальные решения и удовлетворить потребности клиентов еще до их возникновения, что способствует эффективному обслуживанию.

В связи с развитием новых цифровых медиа, появляются новые способы общения пользователей с брендами. Различные системы мониторинга, которые используют движение пальца для отслеживания местонахождения и оплаты, могут размыть границы между предпродажным периодом (реклама/маркетинг) и продажей (покупкой/транзакцией). Применение новых технологий позволяет изменять опыт клиентов, а также способствует созданию бренда с очевидной для покупателей ценностью, что укрепляет их вовлеченность. В качестве примера можно привести успешную компанию Starbucks. Эта компания использует метод таргетирования по геолокации клиентов, которые уже давно не посещали заведение: когда они оказываются возле него, им показывают рекламу новых напитков, которые скоро поступят в продажу [2].

Внедрение ИИ и цифровых технологий в Starbucks через платформу Deep Brew кардинально улучшило персонализацию обслуживания клиентов. Deep Brew анализирует данные о предпочтениях пользователей для настройки маркетинга, рекомендаций продуктов и оптимизации взаимодействия в приложениях и магазинах. Это повысило лояльность клиентов и способствовало значительному росту программы Starbucks Rewards, благодаря целевым предложениям и вознаграждениям, которые стимулируют частые посещения и увеличение расходов [3].

Благодаря такой успешной компании, как Starbucks, клиенты начали ожидать персонализированного подхода с внедрением искусственного интеллекта. Согласно опросу от Epsilon и GBH Insights, 80% из 1000 опрошенных американцев взрослых хотят индивидуального обслуживания от розничных продавцов. Это означает, что клиенты желают персонализированного подхода на всех этапах взаимодействия с брендом, с несколькими точками соприкосновения, соответствующими их предпочтениям. Они хотят получать предложения, адаптированные не только для групп пользователей, но и для них как для индивидуумов, и искусственный интеллект может предоставить такую возможность [4].

Переходя к вопросу о приватности и безопасности данных, ИИ усиливает конфиденциальность, используя передовые методы анонимизации, которые затрудняют отслеживание данных до личности. Сложное шифрование обеспечивает защиту данных при хранении и передаче. ИИ также эффективно обнаруживает и реагирует на угрозы в реальном времени, предотвращая потенциальные нарушения. Он улучшает контроль доступа, управляя, кто может просматривать конфиденциальную информацию, и поддерживает минимизацию данных, собирая только необходимую информацию. Эти меры помогают ИИ эффективно защищать личные данные в современном мире.

Однако и эти нововведения имеют свои недостатки, описанные ниже.

- Переизбыток информации или агрессивный маркетинг. Излишняя персонализация и постоянные уведомления, рассылки и рекламные сообщения могут привести к тому, что клиенты просто перестанут обращать внимание на информацию. Это может снизить эффективность маркетинговых кампаний. Если клиент замечает, что компания использует его данные слишком агрессивно, это может привести к потере доверия [1].

- Отсутствие индивидуального подхода. Хотя ИИ может эффективно автоматизировать многие задачи, он не может воспроизвести тонкие и чуткие аспекты человеческого взаимодействия, которые важны для построения отношений с клиентами. Кроме того, возникают некоторые опасения по поводу сокращения рабочих мест.

- Расходы. ИИ предлагает много возможностей для получения аналитической информации и улучшения маркетинговых стратегий, но внедрение и обслуживание могут стоить дорого, что может оттолкнуть компании от использования новых технологий. Это касается не только начальных инвестиций, но и текущих операционных расходов (техническое обслуживание, модернизация, найм дополнительного персонала) [2].

Затрагивая тему перспективы развития персонализации в контексте новых технологий ИИ, можно выделить следующее.

- Масштабирование операций. По мере роста вашего бизнеса управление расширяющейся клиентской базой становится сложной задачей. ИИ обладает уникальной способностью масштабироваться вместе с ростом вашего бизнеса. Он может обрабатывать все большее количество клиентов без необходимости увеличивать штат сотрудников.

- Поддержание языков всего мира, что позволяет клиентам общаться на родном языке и укрепляя доверие.

- Обеспечивает круглосуточную поддержку, гарантируя оперативное реагирование на запросы в любое время.

- Позволяет более эффективно распределять бюджет на маркетинг, благодаря ему компании могут сосредоточиться на наиболее перспективных сегментах аудитории [6].

Заключение. Персонализация – это мощный инструмент, который при правильном использовании может значительно способствовать росту и развитию бизнеса. Она становится ключевым трендом в маркетинге благодаря её способности улучшать опыт клиентов и увеличивать эффективность маркетин-

говых кампаний. Несмотря на то, что внедрение персонализации требует значительных усилий и инвестиций, её преимущества делают её весьма привлекательной для компаний, желающих оставаться конкурентоспособными на современном рынке. Важно помнить о необходимости соблюдения конфиденциальности данных и этичности их использования, чтобы не потерять доверие клиентов. Для разработки эффективной и качественной программы персонализации необходимо создать команду, которая будет заниматься тестированием и обучением на основе полученных результатов.

Библиографический список

1. Персонализация как ключевой тренд в российском маркетинге. [Электронный ресурс]. Режим доступа: <https://vc.ru/marketing/1399060-personalizaciya-kak-klyuchevoi-trend-v-rossiiskom-marketinge>. – Дата доступа: 12.09.2024.
2. Клиентский опыт в эпоху ИИ. [Электронный ресурс]. Режим доступа: <https://big-i.ru/innovatsii/tekhnologii/klientskiy-opyt-v-epokhu-ii/>. – Дата доступа: 12.09.2024.
3. Case Study: Starbucks Revolutionises the Coffee Experience with AI. [Электронный ресурс]. Режим доступа: <https://aiexpert.network/case-study-starbucks-revolutionizes-the-coffee-experience-with-ai/>. – Дата доступа: 12.09.2024.
4. Epsilon research. [Электронный ресурс]. Режим доступа: <https://www.epsilon.com/us/about-us/pressroom/new-epsilon-research-indicates-80-of-consumers-are-more-likely-to-make-a-purchase-when-brands-offer-personalized-experiences>. – Дата доступа: 12.09.2024.
5. Каковы минусы искусственного интеллекта в маркетинге? [Электронный ресурс]. Режим доступа: https://aimarketingengineers.com/ru/%D0%BA%D0%B0%D0%BA%D0%B8%D0%B5_%D0%BC%D0%B8%D0%BD%D1%83%D1%81%D1%8B_%D0%B0%D0%B9_%D0%B2_%D0%BC%D0%B0%D1%80%D0%BA%D0%B5%D1%82%D0%B8%D0%BD%D0%B3%D0%B5/#. – Дата доступа: 12.09.2024.

PERSONALISATION OF CONSUMER EXPERIENCE WITH ARTIFICIAL INTELLIGENCE

Maria Zelenko

Belarusian State University, 'Institute of Business' in Minsk,
614070, Belarus, Minsk, 7, Oboynaya str.
maria.zelenko.sb@gmail.com

Solushko Arina Sergeevna

Belarusian State University, 'Institute of Business' in Minsk,
7, Oboynaya str., Minsk, 614070, Belarus, Minsk
arina.solushko.sb@gmail.com

The article considers personalisation of customer experience as a key aspect of successful business in the conditions of digital transformation. Artificial intelligence (AI) plays a central role in creating personalised experiences by analysing customer behaviour to improve purchases and business growth. AI improves content relevance, customer loyalty and marketing effectiveness.

Keywords: Personalisation, artificial intelligence, data privacy, consumer behaviour analysis, marketing strategies, advertising technology.

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ЗАРПЛАТЫ PYTHON-РАЗРАБОТЧИКА

Гончаров Сергей Андреевич

Национальный исследовательский университет
«Высшая школа экономики»
614107, Россия, г. Пермь, ул. Бульвар Гагарина, 37а,
e-mail: sagoncharov_1@edu.hse.ru

В статье представлено описание разработки нейросетевой системы для прогнозирования зарплаты python-разработчика. Система позволяет с большой точностью предсказать зарплату python-разработчика на основании его опыта работы и навыков. С помощью разработанной интеллектуальной системы проведено исследование предметной области, выявлены закономерности, имеющие практическое значение.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, трудоустройство, python-разработчик.

Введение. Поиск вакансий является неотъемлемой частью трудоустройства разработчика. Однако, бывает тяжело определить, на какую зарплату можно рассчитывать со своим опытом и навыками, а также, какие умения следует подтянуть для того, чтобы можно было иметь более высокий доход. Для анализа был выбран карьерный путь разработчика, пишущего код на языке программирования python.

При анализе литературных источников выяснилось, что средняя зарплата python-разработчика на 2-е полугодие 2022 года составляла 170 868 рублей в месяц [1-2]. Зарплата Junior-разработчика (опыт от 0 до 1 года) начинается с 70 000 рублей в месяц, Middle-разработчика (опыт от 2 до 3 лет) – со 120 000 рублей, Senior-разработчика (опыт от 5 лет) – с 250 000 рублей.

Среди наиболее востребованных навыков python-разработчиков выделяют [3-4]:

- понимание Python и его структуры данных,
- знание Python-библиотек,
- умение работать с базами данных,
- умение работать с Linux,
- умение работать с системами контроля версий,
- владение английским языком,
- понимание принципов ООП,
- владение web-технологиями.

Основная цель настоящей работы заключается в сборе множества публичных данных о вакансиях для python-разработчиков, а также создание и обучение нейросетевой модели на этих данных. Конечным результатом должна быть нейросетевая система, способная прогнозировать зарплату python-разработчика, основываясь на его опыте и навыках.

Постановка задачи. Для создания нейросетевой системы были выбраны следующие параметры: X_1 – опыт работы разработчика; X_2 - X_{21} – обладание 20 самыми распространенными навыками, требуемыми в вакансиях на одном из сайтов для поиска работы [5]. Выходной параметр – прогнозируемая заработная плата разработчика.

Для определения самых запрашиваемых навыков и сбора обучающего множества была написана программа, работающая с API сайта поиска вакансий. Для наибольшей однородности данных вакансии рассматривались только в Москве на полный рабочий день. Была найдена 251 вакансия, среди которых только 193 содержали информацию о необходимых навыках. Были выделены 20 наиболее часто встречающихся навыков, требуемых от соискателя: Git, Linux, PostgreSQL, SQL, C++, Docker, MySQL, JavaScript, MSSQL, REST, Java, C/C++, HTML, DjangoFramework, ООП, Английский язык, PHP, RabbitMQ, Redis, Kafka. Наличие определенного навыка будет кодироваться 1 и 0 на входных нейронах (1 – есть наличие навыка, 0 – нет наличия). Для этих данных выделены нейроны X_2 - X_{21} соответственно.

После удаления выбросов и отсеивания вакансий без указанной минимальной заработной платы из 193 вакансий осталось 166. Это множество было поделено на обучающее, валидационное и тестирующее в соотношении 85%, 10% и 5% 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 двадцать один входной нейрон, один выходной и один скрытый слой с шестью нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 6 примеров. Средняя относительная ошибка тестирования составила 13.2%, что можно считать приемлемым результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическими и прогнозируемыми нейросетью зарплатами.

Из результатов, изображенных на рис. 1, можно сделать вывод об адекватной работе спроектированной нейронной сети.




Рис. 1. Результат тестирования нейронной сети

Исследование предметной области. Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рис. 2.

Как видно из рис. 2, наиболее значимым параметром для прогнозирования зарплаты является опыт работы. В список из пяти самых наиболее значимых навыков среди соискателей входят: JavaScript, HTML, MySQL, C/C++, Docker. Разработчику необходимо в первую очередь заняться изучением именно этих технологий для того, чтобы получить наибольший прирост к своей потенциальной заработной плате.




Рис. 2. Значимость входных параметров нейросетевой модели

Далее было проведено исследование полученных зависимостей между входными параметрами и результатами прогнозирования. Исследование производилось с помощью метода «замораживания» [7], суть которого заключается в варьировании значения одного параметра и фиксировании значений всех других параметров. Для этой цели был отобран пример, при котором разработчик владеет 5 наиболее востребованными навыками.

На рис. 3 показан график зависимости прогнозируемой зарплаты от опыта работы. Уровень зарплаты с обретением опыта, как и ожидалось, растет. Наибольший прирост зарплаты, исходя из графика, происходит после 3 лет работы.



Рис. 3. Зависимость прогнозируемой зарплаты от опыта работы

Заключение. Построена система нейросетевого прогнозирования зарплаты python-разработчика. Спроектированная нейросетевая модель учитывает 21 параметр: опыт работы и 20 наиболее часто встречаемых навыков в требованиях к вакансиям. Методом сценарного прогнозирования построены графики зависимостей зарплаты от изменения входных параметров. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать потенциальную заработную плату python-разработчика. Данный набор параметров может быть изменен для прогнозирования зарплаты по наличию других навыков.

Библиографический список

1. Skillbox.ru – Сколько зарабатывают Python-разработчики: исследование рынка и зарплат. [Электронный ресурс]. Режим доступа: <https://skillbox.ru/media/code/skolko-zarabatyvayut-pythonrazrabotchiki-issledovanie-rynka-i-zarplat/>
2. Dtf.ru – Python-разработчик: что должен знать и как им стать. [Электронный ресурс]. Режим доступа: <https://dtf.ru/u/735923-productstar/1629041-python-razrabotchik-chto-dolzhen-znat-i-kak-im-stat>
3. Hackr.io – Top 10 Python Skills You Need to Get Hired in 2024. [Электронный ресурс]. Режим доступа: <https://hackr.io/blog/top-python-skills-in-demand>
4. Habr.com – Что нужно знать, уметь и понимать, чтобы не иметь проблем с поиском работы питонистом. [Электронный ресурс]. Режим доступа: <https://habr.com/ru/articles/311642/>
5. Hh.ru. [Электронный ресурс]. Режим доступа: <https://hh.ru/>
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.: Издательский центр «Академия», 2005. – 176 с.

NEURAL NETWORK SYSTEM FOR PREDICTING THE WINNER OF A SNOOKER MATCH

Goncharov Sergey A.

National Research University Higher School of Economics
Studencheskaya Street, 37a, Perm, Russia, 614068, sagoncharov_1@edu.hse.ru

The article describes the development of a neural network system for predicting the salary of a python developer. The system allows to accurately predict the salary of a python developer based on his work experience and skills. With the help of the developed intellectual system, a study of the subject area was carried out, patterns of practical importance were identified.

Keywords: artificial intelligence, neural network, prediction, employment, python developer.

ПРИМЕНЕНИЕ LSTM-НЕЙРОННОЙ СЕТИ И ФРАКТАЛЬНОГО АНАЛИЗА ДЛЯ ПРОГНОЗИРОВАНИЯ ФОНДОВОГО ИНДЕКСА

Гарафутдинов Роберт Викторович

Пермский государственный национальный исследовательский университет,
614068, Россия, г. Пермь, ул. Букирева, 15
rvgarafutdinov@gmail.com

В статье представлены результаты эксперимента по нейросетевому моделированию финансового временного ряда с использованием фрактального анализа. В качестве предиктора на вход нейронной сети помимо исходного ряда был добавлен ряд оценок локальных фрактальных размерностей этого ряда. Результаты: модель, учитывающая фрактальность, дала менее точные прогнозы, что не позволяет заявлять об эффективности фрактальной размерности как предиктора в LSTM-нейронных сетях.

Ключевые слова: фрактальный анализ, нейронная сеть, LSTM, прогнозирование финансовых временных рядов, фрактальная размерность.

Введение. Прогнозирование динамики финансовых рынков, курсов различных финансовых инструментов всегда интересовало инвесторов. Решение этой задачи с достаточно высокой степенью эффективности позволило бы снизить риски и повысить доходность операций на рынках, однако оно по сей день продолжает оставаться желанным, но пока недостижимым. Как показывает объективная действительность, будущее туманно и плохо предсказуемо. Однако интерес к этой теме не снижается. Существуют различные теории, объясняющие природу экономических систем и финансовых рынков в частности, и разработанные в их рамках математические модели, позволяющие в той или иной мере успешно осуществлять краткосрочные прогнозы финансовых временных рядов, например, курсов акций и фондовых индексов. Так, гипотеза фрактального рынка, предложенная Б. Мандельбротом и Э. Петерсом [1], утверждает, что природа рынков является не случайной, а детерминированной, и они поддаются прогнозированию. На эту теорию опираются так называемые эконометрические модели с длинной памятью, такие как ARFIMA и различные фрактальные модификации GARCH. Согласно ряду исследований, учет моделями фрактальных свойств рядов позволяет несколько повышать точность их прогнозов относительно более простых моделей, не учитывающих этих свойств [2].

В настоящее время активно развиваются методы искусственного интеллекта и машинного обучения, предназначенные для решения задачи прогнозирования. Главенствующую роль среди них по праву занимают нейронные сети, способные добиваться точности прогнозов, значительно превышающей таковую более традиционных статистических и эконометрических методов и моделей. Существуют архитектуры нейросетей для обработки последовательностей данных, в том числе и временных рядов произвольной природы. К ним относятся рекуррентные сети с долгой краткосрочной памятью LSTM и GRU. Есть

примеры исследований, показывающих, что такие модели способны успешно прогнозировать и финансовые ряды [3].

Нейронные сети могут работать и с многомерными рядами. Одним из предикторов может выступать оценка фрактальной размерности основного моделируемого ряда. В данной работе производится попытка объединить фрактальный анализ и нейросетевое моделирование и проверить, позволит ли учет моделью фрактальных характеристик финансового временного ряда повысить точность его прогноза. Таким образом, целью исследования является сравнение точности прогнозирования с помощью нейронной сети одномерного ряда и двухмерного, содержащего, помимо финансового ряда, также историю оценок его локальных фрактальных размерностей.

Данные и методы. Объектом прогнозирования был выбран биржевой индекс S&P 500. В исследовании [4] показано, что фрактальный анализ американского фондового рынка дает положительные результаты, и это позволяет иметь некоторые надежды относительно успеха в настоящем исследовании. Были рассмотрены дневные цены закрытия индекса за период с 01.01.2010 по 31.12.2019 гг., всего 2516 наблюдений. График ряда приведен на рис. 1.



Рис. 1. Дневные котировки индекса S&P 500

Источником данных послужил сервис YahooFinance. Для оценивания фрактальной размерности ряда был использован метод ДФА, описанный в [5]. Нейронная сеть обучалась с использованием библиотек Keras и TensorFlow для языка программирования Python.

Методика исследования. По исходным значениям ряда индекса были вычислены оценки его локальных фрактальных размерностей методом скользящего окна шириной 256 и шагом 1. В результате первые 255 наблюдений ряда были отброшены (для них не было значений размерности). Оставшиеся данные были поделены на тестовую (последние 30 значений) и обучающую выборки. Задача прогнозирования временного ряда – это частный случай задачи регрессии. Целевым признаком явилось значение прогнозируемого ряда в момент времени $t + 1$, в качестве факторных признаков были взяты значения ряда в мо-

менты времени $\{t_1, t_2, \dots, t_{255}, t_{256}\}$ и соответствующие оценки размерностей. Таким образом, нейросети обучались для прогнозирования на один шаг вперед с использованием данных предыдущих 256 наблюдений. Всего было обучено две нейросети: для прогнозирования с использованием оценок размерностей и с использованием только ряда значений индекса. Данные были нормализованы методом z-стандартизации и приведены к виду, пригодному для подачи их на вход сетей.

Каждая сеть состояла из входного слоя соответствующей исходным данным размерности, двух LSTM-слоев по 128 и 64 нейрона соответственно и одного выхода. Архитектура сети с двумя рядами на входе приведена на рис. 2.




Рис. 2. Архитектура нейросети, учитывающей фрактальные свойства ряда

При обучении обеих моделей использовался оптимизатор Adam. Функция потерь – *MAE*, размер пакета данных (батча) 32, количество эпох обучения 100. Также для борьбы с переобучением сети был использован механизм ранней остановки обучения EarlyStopping, критерий остановки – не уменьшение значения функции потерь в течение трех эпох. В результате, как выяснилось, сети не обучались более чем 20 эпох, срабатывал механизм остановки.

Прогнозы ряда индекса были получены для всех 30 временных точек тестовой выборки. Точность прогнозирования оценивалась по метрике *MAE*. Учитывая, что в Keras веса нейронной сети инициализируются случайными значениями, а значит, начальная точка оптимизатора разная при каждом запуске обучения модели, в целях повышения статистической надежности результатов было решено обучить обе сети десятикратно, а полученные значения метрики точности прогноза усреднить. Перед расчетом *MAE* для прогнозных значений была выполнена «обратная нормализация», метрика вычислялась по исходным значениям индекса.

Результаты и обсуждение. На рис. 3 приведен график фактических и прогнозных значений индекса, полученный в результате одного из запусков обучения моделей.



Рис. 3. Сравнение фактических и прогнозных данных

Можно заметить, что график прогноза модели, использующей ряд размерностей, более сглаженный, чем график второй модели, и хуже него повторяет фактические данные. Такая ситуация явилось типичной для всех запусков. Среднее значение MAE для фрактальной модели составило $40,86 \pm 13,77$, а для второй модели $31,39 \pm 9,87$ (приведены 95%-ые доверительные интервалы). Также можно отметить, что первая нейросеть быстрее переобучалась, для нее раньше срабатывал механизм ранней остановки.

Таким образом, нейросеть, использующая только сами данные исходного ряда, показала более высокую точность прогнозирования. Использование фрактальной размерности как предиктора оказалось неэффективным. Возможной причиной этого факта может являться следующая. Фрактальная размерность не является внешней информацией, она оценивается по самому ряду. Нейросети не интерпретируемы, результаты их работы плохо поддаются обоснованию. Возможно, нейронная сеть всю полезную для объяснения целевого признака информацию, какую только может, извлекает из данных сама.

Также можно изложить следующие соображения относительно общей целесообразности применения нейросетевых моделей для прогнозирования таких сложных, нестационарных (в самом широком смысле) временных рядов, как финансовые. Методы машинного обучения для качественной работы требуют очень больших объемов данных. На финансовых рынках данные в достаточном количестве доступны не всегда и даже практически никогда, если вести речь не о сотнях или тысячах наблюдений, а о сотнях тысяч и миллионах. Чтобы получить выборки столь значительного объема, придется обращаться не к дневным и тем более не к недельным или месячным данным, а к часовым и минутным. С доступностью такой информации неизбежно возникнут проблемы. Но даже при ее наличии можно задаться справедливым вопросом: уместно ли использовать значения котировок несколько тысяч часов назад для предсказания котировки актива в следующий час? Маловероятно, что подобная зависимость существует. Финансовые рынки – системы с очень изменчивой динамикой. Проблема обнаружения «разладки», в том числе изменения локальных фрактальных свойств, в литературе об-

суждалась (см., например, [6]). Возможно, для краткосрочного прогнозирования в большей степени подходят модели, не основанные на искусственном интеллекте, которым для обучения достаточно нескольких десятков значений.

Заключение. В результате исследования было выполнено сравнение точности прогнозов, полученных с помощью двух нейросетевых моделей: учитывающей фрактальные свойства исследуемого ряда и не учитывающей. Более точный прогноз был получен с помощью нефрактальной модели. Можно сделать вывод, что применение оценок локальных фрактальных размерностей финансового ряда как предиктора в простой LSTM-сети не улучшает качества прогнозирования.

Ограничения использованной методики исследования: не применялась валидационная выборка для обнаружения переобучения моделей; тонкий подбор гиперпараметров моделей не производился; прогноз осуществлялся только на один шаг вперед. Возможным направлением исследований является устранение перечисленных недочетов, а также увеличение информационной базы исследования (взять больше финансовых инструментов, расширить временные рамки). Также имеет смысл испробовать другие методы оценивания фрактальных характеристик временных рядов (в частности, метод минимального покрытия).

Библиографический список

1. Петерс Э. Фрактальный анализ финансовых рынков: применение теории хаоса в инвестициях и экономике. – М.: Интернет-трейдинг, 2004. – 304 с.
2. Балагула Ю.М. Прогнозирование суточных цен на ОПЭМ РФ с помощью модели ARFIMA // Прикладная эконометрика. – 2020. – Т. 57. – С. 89–101. DOI: 10.22394/1993-7601-2020-57-89-101
3. Патласов Д.А., Гарафутдинов Р.В. Применение нейронных сетей архитектуры LSTM для моделирования волатильности фондового рынка // Вестник Пермского университета. Серия: Экономика. – 2024. – Т. 19, № 1. – С. 41–51. DOI 10.17072/1994-9960-2024-1-41-51
4. Garafutdinov R. An Optimal Investment Portfolio Constructed with Fractal Analysis and Long Memory Models // Lecture Notes in Networks and Systems. – 2022. – Vol 342. – Pp. 1116–1131. DOI: 10.1007/978-3-030-89477-1_99
5. Peng C.-K. Mosaic organization of DNA nucleotides / C.-K. Peng, S.V. Buldyrev, S. Havlin, M. Simons, H.E. Stanley, A.L. Goldberger // Physical Review E. – 1994. – Vol. 49, No. 2. – Pp. 1685–1689. DOI:10.1103/PhysRevE.49.1685
6. Гарафутдинов Р.В. К задаче классификации участков финансовых временных рядов различной фрактальной размерности // Татищевские чтения: актуальные проблемы науки и практики: материалы XVII Международной научно-практической конференции. – 2020. – С. 226–230.

STOCK INDEX FORECASTING USING LSTMNEURAL NETWORK AND FRACTAL ANALYSIS

Robert V. Garafutdinov

Perm State National Research University,
Bukireva str., 15, Perm, Russia, 614068
rvgarafutdinov@gmail.com

The paper presents the results of the experiment on neural network modelling of financial time series using fractal analysis. As a predictor, a number of estimates of local fractal dimensions of this series was added to the input of the neural network in addition to the input series. Results: the model taking into account fractality gave less accurate predictions, which does not allow us to declare the effectiveness of fractal dimension as a predictor in LSTM neural networks.

Keywords: fractal analysis, neural network, LSTM, financial time series forecasting, fractal dimension.

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ РАЗВИТИЯ ИНФРАСТРУКТУРЫ КАМПУСА НИУ ВШЭ – ПЕРМЬ

Васильев Вадим Дмитриевич

Национальный исследовательский университет
«Высшая школа экономики» в Перми,
614070, Россия, г. Пермь, ул. Студенческая, 38
vdvasilev_2@edu.hse.ru

В статье представлено описание разработки нейросетевой системы для прогнозирования развития инфраструктуры кампуса НИУ ВШЭ – Пермь. Система позволяет с большой точностью предсказать количество единиц оборудования (комплекса технических средств), которое потребуется использовать в ближайшее время на основании данных о количестве техники за период с 1998 по 2024 г. С помощью разработанной интеллектуальной системы проведено исследование предметной области, выявлены закономерности, имеющие практическое значение.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, комплекс технических средств, программное обеспечение, инфраструктура, компьютерный центр, база данных.

Введение. Компьютерный центр (КЦ) НИУ ВШЭ – Пермь – это организация, которая ведёт учёт объектов ИТ-инфраструктуры, таких как комплекс технических средств (КТС) и программное обеспечение (ПО) на территории всех учебных корпусов в пермском кампусе НИУ ВШЭ.

База данных (БД) КЦ обширная, т.к. по данным Третьякова Степана Владимировича (начальника компьютерного центра) содержит более 100 наименований ПО, а также различные виды компьютерного, коммутационного и периферийного оборудования в составе более 1500 единиц.

Важность и необходимость проведения исследования по данной теме обуславливается тем, что в настоящее время НИУ ВШЭ – Пермь активно развивается: усовершенствуются существующие образовательные программы (ОП), требующие использования ПО и КТС – программы бакалавриата, магистратуры, дополнительного образования, такие как «Бизнес-информатика», «Программная инженерия», «Бизнес-аналитика», «Финансовые стратегии и аналитика», «Управление развитием бизнеса». Кроме того, появляются новые образовательные программы («Дизайн», «Программные системы и автоматизация процессов разработки», «Разработка информационных систем для бизнеса»), также растёт количество абитуриентов, соответственно растёт количество компьютерных классов, используемого ПО, компьютеров, пользователей. Следовательно, бумажный учёт ПО и КТС, а также их прогнозирование с помощью карточек учёта оборудования и с помощью Excel-таблиц, используемое на протяжении примерно 20 лет, перестаёт удовлетворять требованиям вычислительного центра (ВЦ) НИУ ВШЭ – Пермь, т.к. каждой ОП требуются разные программные средства (ПС), а КЦ не в состоянии обеспечивать данные потребности ОП.

Таким образом, КЦ НИУ ВШЭ – Пермь нуждается в системе, позволяющей учитывать объекты ИТ-инфраструктуры университета, т.е. ПО и КТС, производить прогнозирование и мониторинг, а также поддерживать актуальную информацию о программном обеспечении, чтобы понимать, какие виды ПО требуются в определённый момент.

Постановка задачи и формирование DataSet. Для создания нейросетевой системы были выбраны следующие параметры: входной параметр (X1) – годы жизни университета; выходной параметр (Y1) – количество единиц оборудования (компьютеров в компьютерных классах) на определённый год (с 1998 по 2024 гг.).

Набор данных был получен от начальника КЦ НИУ ВШЭ – Пермь. Перед переходом к проектированию и обучению нейросетевой модели, была выполнена очистка исходного множества от противоречивых примеров, выбросов, дубликатов. Данное множество было разделено на обучающее и тестирующее в соотношении 90% и 10% соответственно.

Проектирование нейронной сети. Проектирование, обучение и тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [1] по методике [2]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет один входной нейрон, один выходной и один скрытый слой с семью нейронами.

Реализация. Для начала необходимо собрать имеющиеся данные воедино. Для этого потребуется таблица в формате Excel:

Неуд/год	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
201(1)	0	0	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15
202(1)	0	0	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15
301(1)	0	0	0	0	0	0	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15
101(2)	0	0	0	0	0	0	0	15	15	15	15	15	15	15	0	0	0	0	0	0	21	21	21	21	21	21	21
210(2)	0	0	0	0	0	0	0	15	15	15	15	15	15	0	0	0	0	0	0	0	21	21	21	21	21	21	21
211(2)	0	0	0	0	0	0	0	0	0	15	15	15	15	15	0	0	0	0	0	0	21	21	21	21	21	21	21
206(3)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	21
304(3)	0	0	0	0	0	0	0	0	0	0	0	15	15	15	15	15	15	15	15	15	15	15	15	15	15	15	0
305(3)	0	0	0	0	0	0	0	0	0	0	0	0	0	16	16	16	16	16	16	16	16	16	16	16	16	16	21
504(3)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	21	21	21	21	21	21	21	21	21	21	21	21
509(3)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	21	21	21	21	21	21	21	21	21	21	21	21
510(3)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	21	21	21	21	21	21	21	21	21	21	21	21
511(3)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	21	21	21	21	21	21	21	21	21	21	21	21
316(4)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15	15	15	15	15	15	15	15	15	15	15	0	0
317(4)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15	15	15	15	15	15	15	15	15	15	15	15
137(7)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15	15	15
Лицей №10 (1)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Лицей №10 (2)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Лицей №10 (3)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Лицей №10 (4)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Сумма компьютеров в комп. классах	0	0	30	30	30	30	45	60	75	90	90	105	105	106	160	175	190	190	190	190	253	253	253	253	268	274	276

Рис. 1. Набор имеющихся данных

Далее следует работа с нейросимулятором, а именно: задаётся количество нейронов на входном слое, количество скрытых слоев и количество нейронов на скрытом слое:




Рис. 2. Нейронная сеть на платформе «Нейросимулятор»

После этого осуществляется ввод имеющихся данных, представленных на рис.1, с разбивкой на обучающее и тестирующее множество в соотношении 90% и 10% соответственно для обучения нейросети:

Затем необходимо приступить к обучению нейросети:




Рис. 3. Обучение нейросети

Далее следует этап проверки. Выявлено, что проверка прошла успешна. Следовательно, необходимо приступить к этапу прогнозирования на несколько лет вперед. Стоит отметить, что прогноз верный: в последнее время не наблюдается резких скачков. Каждый год количество компьютеров в компьютерных классах либо увеличивалось (плавно или резко), либо оставалось неизменным, но не уменьшалось. Полученные результаты оптимальнее всего отобразить графически:



Рис. 4. Распределение количества компьютеров

Проверку адекватности необходимо выполнить путём построения соответствующей столбчатой диаграммы:




Рис. 5. Анализ адекватности

Расчёт коэффициента Пирсона и коэффициента детерминации: коэффициент Пирсона равен 0,83, коэффициент детерминации равен 0,70. Вывод: модель хорошая.

Необходимо выполнить анализ полученных данных (графически сравнить фактические значения распределения компьютеров по годам со значениями, полученными с помощью нейросети):




Рис. 6. Графическое сравнение фактических значений и значений, прогнозируемых нейросетью

Очевидно, что значения совпадают, а нейросеть строит прогнозируемые точки в соответствии с тенденцией – это ещё одно подтверждение того, что нейросеть обучена, т.к. справилась с задачей успешно.

Заключение. В результате исследования построена система нейросетевого прогнозирования объектов ИТ-инфраструктуры университета.

Спроектированная нейросетевая модель учитывает входные параметры – годы жизни университета, а выходными параметрами является количество единиц оборудования, т.е. компьютеров в компьютерных классах на определённый год (в конкретном случае с 1998 по 2024 гг.). Методом прогнозирования построены графики зависимостей количества единиц оборудования от изменения входных параметров.

Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать количество требуемой техники на тот или иной период.

Исходя из исследования итоговых результатов, система работает корректно и может в полной мере использоваться сотрудниками компьютерного центра университета.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
3. М. А. Пласкин Тестирование и отладка программ для профессионалов будущих и настоящих, изд. «БИНОМ. Лаборатория знаний», 2007 – 170с.
4. Карпунин А. А., Ганев Ю. М., Чернов М. М. Методы обеспечения качества при проектировании сложных программных систем //Надежность и качество сложных систем. – 2015. – №. 2 (10). – С. 78-84.
5. Официальный сайт компьютерного центра НИУ ВШЭ – Пермь. [Электронный ресурс]. – Режим доступа: https://perm.hse.ru/pc_centre/ (25.09.2023)

NEURAL NETWORK SYSTEM FOR FORECASTING THE DEVELOPMENT OF INFRASTRUCTURE OF THE HSE CAMPUS – PERM

Vasiliev Vadim Dmitrievich

HSE University,
Str. Studencheskaya, 38, Perm, Russia, 614070
vdvasilev_2@edu.hse.ru

The article presents a description of the development of a neural network system for predicting the development of infrastructure on the campus of the National Research University Higher School of Economics – Perm. The system allows you to predict with great accuracy the number of pieces of equipment (a set of technical means) that will need to be used in the near future based on data on the amount of equipment for the period from 1998 to 2024. Using the developed intelligent system, a study of the subject area was carried out, and patterns of practical importance were identified.

Keywords: artificial intelligence, neural network technologies, forecasting, complex of technical means, software, infrastructure, computer center, database.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ДЛЯ ФОРМИРОВАНИЯ ЭКОНОМИКИ ЗАМКНУТОГО ЦИКЛА

Колесник Надежда Александровна

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

В статье рассмотрено использование технологий искусственного интеллекта для формирования экономики замкнутого цикла. Были систематизированы ключевые инициативы и практики в соответствии с производственно-сбытовой цепочкой по трём направлениям формирования экономики замкнутого цикла: сокращение (reduce), повторное использование (reuse), переработка (recycle). Систематизация направлений использования искусственного интеллекта по этапам производственно-сбытовой цепочки позволяет использовать большой потенциал технологий для большего благополучия бизнеса, экологии и общества.

Ключевые слова: искусственный интеллект, экономика замкнутого цикла, продуктовая отрасль, экология.

Введение. Экология остаётся одной из важных проблем в России и мире, что отражается в Целях устойчивого развития и Национальных целях развития России. Переход к экономике замкнутого цикла, как одной из целей в перспективе до 2036, представляет собой комплексную задачу взаимодействия государства, бизнеса и общества [1]. Особая актуальность исследования продуктового ритейла связана с тем, что продуктовая отрасль является одним из наибольших источников создания отходов [2], по данным Российского экологического оператора в структуре мусора содержится около 50 % составляет одноразовая упаковка от продуктов питания и около 40 % пищевых отходов.

Экономика замкнутого цикла в разных отраслях и бизнес-моделях имеет свою специфику. В академической литературе встречается более 221 определений, содержательно основанных на трёх ключевых направлениях реализации [3]:

- сокращение количества используемых ресурсов (reduce), в том числе за счёт отказа (refuse), переосмысления (rethinking), перепроектирования (redesigning) (включая продление срока службы продуктов), минимизации, оцифровки;
- продление срока и повторное использование (reuse) ресурсов, включая ремонт (repairing) и восстановление (refurbishing);
- переработка (recycle).



Рис. 1. Производственно-сбытовая цепочка продуктов питания (food value chain)

Источник: Catalysing Science-based Policy Action on Sustainable Consumption and Production: The Value-chain Approach, UN environment programme, 2021.

Анализ производственно-сбытовой цепочки. Рассматривать внедрение экономики замкнутого цикла целесообразно исходя из производственно-сбытовой цепочки отрасли.

Наибольшими ресурсами и возможностями для внедрения аспектов экономики замкнутого цикла обладают участники средних этапов производственно-сбытовой цепочки. Участники средних этапов не используют большие объёмы природных ресурсов сами, но являются мощными в структурном и финансовом отношении, оказывая огромное влияние на деятельность других участников, как на первичное производство, так и на конечное потребление [4].

Использование искусственного интеллекта для формирования экономики замкнутого цикла. Алгоритмы искусственного интеллекта могут анализировать огромные наборы данных для выявления неэффективности использования ресурсов, оптимизации процессов, более эффективного управления отходами, распределения ресурсов, предиктивного обслуживания оборудования, и разработки решений продления жизненных циклов продуктов [5]. Согласно исследованию Сколково 80 % руководителей компаний считают, что главным преимуществом внедрения цифровых инструментов является повышение производительности и эффективности процессов в компании, а также получение дополнительных экологических и социальных эффектов [6]. Несмотря на признание того факта, что обучение нейросетей требуют существенных ресурсов и издержек для окружающей среды, искусственный интеллект может внести вклад для экологии.

Использование искусственного интеллекта и внедрение принципов экономики замкнутого цикла

Выращивание и сбор продукции		
Мониторинг за процессами Прогноз роста Контроль за температурой и влажностью	Оптимизация ▪ структуры посева ▪ использования пестицидов и удобрений ▪ системы полива	Albaaji G. F., SS V. C. Artificial intelligence SoS framework for sustainable agricultural production //Computers and Electronics in Agriculture. – 2023. – Т. 213. – С. 108182. Rustia D. J. A. et al. Towards intelligent and integrated pest management through an AIoT based monitoring system //Pest Management Science. – 2022. – Т. 78. – №. 10. – С. 4288-4302. Sharma R. Artificial intelligence in agriculture: a review //2021 5th international conference on intelligent computing and control systems (ICICCS). – IEEE, 2021. – С. 937-942.
Переработка и упаковка товаров		
Снижение брака и повышение качества продукции	Моделирование и оптимизация производственного процесса: ▪ снижение затрат ресурсов ▪ повышение эффективности использования ресурсов	Kumar I. et al. Opportunities of artificial intelligence and machine learning in the food industry //Journal of Food Quality. – 2021. – Т. 2021. – №. 1. – С. 4535567. Matin A. et al. AIoT for sustainable manufacturing: Overview, challenges, and opportunities //Internet of Things. – 2023. – С. 100901. Ramirez-Asis E. et al. A review on role of artificial intelligence in food processing and manufacturing industry //Materials Today: Proceedings. – 2022. – Т. 51. – С. 2462-2465.
Транспортировка и хранение		
Оптимизация логистических процессов Прогноз логистических потребностей	▪Снижение расходов и расходов топлива ▪Повышение эффективности загрузки ▪Оптимизация складских операций и хранения	Richey Jr R. G. et al. Artificial intelligence in logistics and supply chain management: A primer and roadmap for research //Journal of Business Logistics. – 2023. – Т. 44. – №. 4. – С. 532-549. Jackson I. et al. Generative artificial intelligence in supply chain and operations management: a capability-based framework for analysis and implementation //International Journal of Production Research. – 2024. – С. 1-26. Richey R. G. et al. Artificial intelligence in logistics and supply chain management: A primer and roadmap for research //Journal of Business Logistics. – 2023. – Т. 44. – №. 4.
Розничная торговля		
Повышение эффективности продаж и сокращение потерь готовой продукции	▪ Прогноз спроса ▪ Прогноз остатков ▪ Взаимодействие с потребителем, (например, оплата взглядом)	Oosthuizen K. et al. Artificial intelligence in retail: The AI-enabled value chain //Australasian Marketing Journal. – 2021. – Т. 29. – №. 3. – С. 264-273. Heins C. Artificial intelligence in retail—a systematic literature review //Foresight. – 2023. – Т. 25. – №. 2. – С. 264-286. Yau K. L. A., Saad N. M., Chong Y. W. Artificial intelligence marketing (AIM) for enhancing customer relationships //Applied Sciences. – 2021. – Т. 11. – №. 18. – С. 8562.

Индивидуальное потребление		
Оптимизация совершенства покупок по содержанию (необходимости) и количеству	Персонализированные рекомендации по товарам на основе анализа данных поведения пользователей Оптимизация использования имеющихся продуктов	Puntoni S. et al. Consumers and artificial intelligence: An experiential perspective //Journal of Marketing. – 2021. – Т. 85. – №. 1. – С. 131-151. Kim J., Kang S., Bae J. The effects of customer consumption goals on artificial intelligence driven recommendation agents: evidence from Stitch Fix //International Journal of Advertising. – 2022. – Т. 41. – №. 6. – С. 997-1016. Hermann E. Artificial intelligence in marketing: friend or foe of sustainable consumption? //AI & SOCIETY. – 2023. – Т. 38. – №. 5. – С. 1975-1976.
Утилизация и переработка		
Сортировка отходом	Повышение эффективности до-сортировки отходов.	Fang B. et al. Artificial intelligence for waste management in smart cities: a review //Environmental Chemistry Letters. – 2023. – Т. 21. – №. 4. – С. 1959-1989.
Анализ свалок	Обучение нейросетей для распознавания нелегальных свалок на спутниковых снимках	Геоаналитическая платформа «Геометрия», разработанная Sber AI. В России стартовал проект по применению нейросети для очищения страны от мусора. 2023. [Электронный ресурс]. Режим доступа: https://www.gazeta.ru/tech/news/2023/10/10/21472231.shtml

Заключение. В результате исследования были систематизированы основные направления использования искусственного интеллекта для формирования экономики замкнутого цикла по этапам на примере производственно-сбытовой цепочки продуктов питания.

С учётом высокой стоимости использования технологий, основанной на оплате труда высококвалифицированных сотрудников и затрат на специализированное высокотехнологическое оборудование для обработки данных и обучения, потенциалом по внедрению искусственного интеллекта обладают центральные участники цепочки, для которых характерен высокий уровень консолидации и наличие необходимых значимых ресурсов.

Внедрение цифровых технологий, в частности искусственного интеллекта является перспективным аспектом для формирования экономики замкнутого цикла в том случае, когда возникает **синергетический эффект** в повышении эффективности бизнес-процессов и результативности компании. Ключевые направления использования искусственного интеллекта для сбора информации, обработки не структурированных данных и предиктивной аналитики для снижения издержек и повышения эффективности производства за счёт снижения ресурсоёмкости и повышения энерго-эффективности, повышения эффективности работы оборудования, оптимизации логистических процессов, эффективности продаж и взаимодействия с потребителями.

Библиографический список

1. Минэконом развития РФ 2021. Экономика замкнутого цикла. [Электронный ресурс]. Режим доступа: <https://www.economy.gov.ru/material/file/55fc716c49b06e62a652d101b1be8442/220414.pdf>

2. World Bank. What a waste 2.0: a global snapshot of solid waste management to 2050. – World Bank Publications, 2018.
3. Kirchherr J. et al. Conceptualizing the circular economy (revisited): an analysis of 221 definitions //Resources, Conservation and Recycling. – 2023. – Т. 194. – С. 107001.
4. Колесник Н. А. Реализация концепции устойчивого развития в сфере розничной торговли: латентный семантический анализ SMM-коммуникации 2015–2021 гг //Журнал новой экономической ассоциации. – 2023. – С. 79.
5. Kowsari E. et al. Marine plastics, circular economy, and artificial intelligence: A comprehensive review of challenges, solutions, and policies //Journal of Environmental Management. – 2023. – Т. 345. – С. 118591.
6. Центр устойчивого развития Школы Управления Сколково. ESG в цифровом мире: вызовы и возможности. 2022. – 26 с.

ARTIFICIAL INTELLIGENCE FOR CREATING A CLOSED-LOOP ECONOMY

Nadezda A. Kolesnik

National Research University «Higher School of Economics»,
Str. Mysnickaya, 20, Moscow, Russia, 101000
nkolesnik@hse.ru

The article examines the use of artificial intelligence technologies to form a closed-loop economy. Key initiatives and practices were systematized in accordance with the food supply chain in three areas of forming a closed-loop economy: reduce, reuse, and recycle. Systematization of artificial intelligence technologies by stages of the supply chain allows using the great potential of the food industry for greater well-being of business and society.

Keywords: artificial intelligence, circular economy, food industry, ecology

УДК 004.032.26

AI-АНАЛИТИКА И ОПТИМИЗАЦИЯ КЛИЕНТСКОГО ОПЫТА: ОТ ПРОГНОЗИРОВАНИЯ ПОВЕДЕНИЯ ДО АВТОМАТИЗАЦИИ ОБСЛУЖИВАНИЯ

Куцая Александра Андреевна

Финансовый Университет при Правительстве Российской Федерации,
125167, Москва, пр-кт Ленинградский, д. 49/2
sasha1642003@mail.ru

Статья посвящена роли искусственного интеллекта (AI) в оптимизации клиентского опыта, охватывая использование AI-аналитики и автоматизации обслуживания. Рассматривается, как AI-технологии помогают бизнесам предсказывать поведение клиентов, персонализировать их взаимодействие и автоматизировать процессы обслуживания. Примеры успешного применения включают кейсы Т-Банка и СберБанка, где AI-алгоритмы используются для персонализации предложений и автоматизации работы контакт-центров. В статье также обсуждаются результаты применения AI, такие как повышение удовлетворенности и лояльности клиентов, а также влияние на рабочие процессы и производительность сотрудников.

Ключевые слова: AI-аналитика, персонализация, автоматизация обслуживания, клиентский опыт, прогнозирование поведения, чат-боты, виртуальные помощники, Т-Банк, СберБанк, нейросетевые технологии, эффективность обслуживания, лояльность клиентов.

Введение. В условиях современной конкуренции компании стремятся к улучшению клиентского опыта, что становится ключевым фактором успеха на рынке. Искусственный интеллект (AI) играет центральную роль в этом процессе, помогая бизнесам оптимизировать взаимодействие с клиентами на всех этапах – от прогнозирования их поведения до автоматизации обслуживания. Использование AI-аналитики позволяет компаниям не только предугадывать потребности своих клиентов, но и персонализировать предлагаемые решения, улучшая уровень удовлетворенности и лояльности. В данной работе будет рассмотрено, как AI-технологии трансформируют клиентский опыт с помощью аналитики данных и автоматизации, на примере российских кейсов банков Т-Банк и СберБанк.

Проблематика: Как AI помогает улучшать клиентский опыт через прогнозирование поведения, автоматизацию customer support и создание персонализированных стратегий. В работе использовались общие научные методы исследования такие как анализ, синтез, классификация, сравнительный анализ. В качестве социальных научных методов применен контент-анализ.

AI-аналитика для прогнозирования поведения клиентов. AI-аналитика играет ключевую роль в прогнозировании поведения клиентов, позволяя компаниям выявлять паттерны и предсказывать их будущие действия. Используя возможности анализа больших данных, AI-алгоритмы могут обрабатывать историю покупок, предпочтения клиентов, а также внешние факторы, влияющие на принятие решений. Примером эффективного применения AI-аналитики является Тиньков (Т-Банк), который использует алгоритмы для персонализации кэшбэк-оферов [1]. Эти алгоритмы подбирают наиболее релевантные предложения, основываясь на предыдущих транзакциях и предпочтениях клиентов, что способствует увеличению удовлетворенности и лояльности клиентов.

Результаты, подчеркивающие бизнес-эффект внедрения AI-технологий в работу банка:

- Увеличение доли клиентов, воспользовавшихся хотя бы одним спецпредложением, на 10%;
- Увеличение доли клиентов, совершивших хотя бы одну покупку по спецпредложению, на 11%;
- Экономия в 80 млн рублей за счет оптимизации процесса выплаты кэшбэка до конца 2021 года.

Имиджевый эффект:

- Рост удовлетворенности клиентов разделом спецпредложений;
- Повышение лояльности клиентов.

Персонализация клиентского опыта с помощью AI. Персонализация клиентского опыта с помощью AI становится важным инструментом для улучшения взаимодействия клиентов с брендом. AI-технологии позволяют автоматически генерировать персонализированные предложения и рекомендации, что существенно повышает качество обслуживания и удовлетворенность клиентов. Благодаря сегментации аудитории с использованием AI-систем, компании могут предлагать релевантные продукты и услуги, что увеличивает вероятность совершения покупок. Примером успешного использования AI является СберБанк, который с помощью машинного обучения выявляет потребности клиен-

тов и формирует индивидуальные предложения, основываясь на их данных, что улучшает клиентский опыт и повышает лояльность [2].

Автоматизация обслуживания клиентов. В области автоматизации обслуживания клиентов AI-решения, такие как чат-боты и виртуальные помощники, играют ключевую роль в оптимизации работы контакт-центров. Эти технологии значительно снижают нагрузку на операторов, улучшая при этом скорость и эффективность обслуживания. Чат-боты способны обрабатывать запросы клиентов, предоставлять рекомендации и решать возникающие проблемы в реальном времени, зачастую опережая ожидания пользователей. Примером успешного применения таких решений является СберБанк, который использует чат-боты для автоматизации обслуживания. Эти чат-боты, опираясь на аналитические данные, могут предвосхищать запросы клиентов и таким образом значительно снижать нагрузку на операторов.

Влияние AI на рабочий процесс согласно зарубежному исследованию. Недавние исследования показывают, что новые инструменты искусственного интеллекта могут значительно изменить рабочие процессы и обучение сотрудников. В исследовании, проведённом Национальным бюро экономических исследований (National Bureau of Economic Research) на основе данных 5179 агентов службы поддержки клиентов, поэтапное внедрение генеративного AI-помощника для разговоров показало прирост производительности в среднем на 14%, измеряемый по числу решённых проблем в час [5]. Важно отметить, что новички и низкоквалифицированные сотрудники улучшили свои результаты на 34%, тогда как влияние на опытных и высококвалифицированных работников было минимальным. Исследование подтверждает, что AI способствует распространению лучших практик среди менее опытных сотрудников, помогая им быстрее развиваться. Кроме того, поддержка AI улучшила настроение клиентов, увеличила удержание сотрудников и способствовала их обучению. Эти данные подтверждают, что генеративный AI может существенно повысить производительность, хотя его влияние варьируется в зависимости от уровня квалификации сотрудников (рис. 1).




Рис. 1. Влиянии AI на производительность сотрудников

Но, согласно еще одному исследованию, опубликованному в апреле этого года, глобальный бенчмарк для CSAT колеблется в пределах 75%–80%, что отражает стандартное качество предоставления услуг в индустрии [4].

Оценка удовлетворенности клиентов (CSAT) – это метрика, которая измеряет степень удовлетворенности клиентов качеством поддержки, обычно собираемая через опросы после взаимодействия с сервисом или с помощью механизмов обратной связи. CSAT является ключевым показателем качества обслуживания и взаимодействия с клиентами. При этом средняя скорость ответа (ASA): среднее время, необходимое для ответа на входящие звонки агентом поддержки, согласно глобальному бенчмарку, составляет: 34,4 секунды.

Важно учитывать, что, во-первых, опросы часто отражают крайние точки зрения респондентов. Во-вторых, реакция зависит от целевой аудитории бизнеса и её восприятия технологических нововведений.

Повышение лояльности и удержание клиентов. Персонализированные рекомендации и высокое качество обслуживания создают для клиентов ощущение заботы и повышают лояльность к бренду. Системы AI помогают брендам оставаться конкурентоспособными, предвосхищая ожидания клиентов и предоставляя максимально релевантные предложения.

Заключение. Искусственный интеллект становится неотъемлемым инструментом в создании и оптимизации клиентского опыта. AI-аналитика позволяет компаниям предсказывать поведение клиентов, персонализировать их взаимодействие с брендом и автоматизировать обслуживание, делая его более эффективным. Кейсы Т-Банка и СберБанка демонстрируют успешные примеры использования AI для оптимизации клиентского опыта, что приводит к повышению удовлетворенности и лояльности клиентов. В дальнейшем AI будет играть еще более важную роль в трансформации бизнес-процессов и взаимодействии с клиентами.

Библиографический список

1. Персональный кэшбэк для клиентов банка. Сентябрь, 2020 год. Технология алгоритмического кэшбэка Tinkoff. // AI Russia URL: <https://ai-russia.ru/library/tinkoff-cashback> (дата обращения: 15.09.2024).
2. Предвосхищение желаний клиентов Сбера 2021 год. Сервис предиктивной аналитики для определения задач и проблем клиентов Сбера до обращения на линию поддержки // AI Russia URL: <https://ai-russia.ru/library/sber-predictive> (дата обращения: 15.09.2024).
3. Как искусственный интеллект улучшает клиентский сервис // Русская школа управления URL: <https://uprav.ru/blog/ai-and-customers/> (дата обращения: 14.09.2024).
4. Call Center Benchmarking: 10 Key Metrics & Industry Standards. By D. Proshchakov | 3 Apr 2024 | Call Center, Metrics // CLOUDTALK URL: <https://www.cloudtalk.io/blog/5-call-center-metrics-for-successful-benchmarking/> (дата обращения: 14.09.2024).
5. Generative AI at Work Erik Brynjolfsson, Danielle Li, and Lindsey R. Raymond NBER Working Paper No. 31161 April 2023, revised November 2023 JEL No. D8,J24,M15,M51,O33.

AI ANALYTICS AND CUSTOMER EXPERIENCE OPTIMIZATION: FROM BEHAVIOR PREDICTION TO SERVICE AUTOMATION

Kutsaya Alexandra Andreevna

Financial University under the Government of the Russian Federation,
Leningradsky Ave., 49/2, Moscow, Russia, 125167,
sasha1642003@mail.ru

This article explores the role of artificial intelligence (AI) in optimizing customer experience, covering the use of AI analytics and service automation. It examines how AI technologies help businesses predict customer behavior, personalize their interactions, and automate service processes. Examples of successful application include the cases of T-Bank and SberBank, where AI algorithms are used to personalize offers and automate contact center operations. The article also discusses the results of AI application, such as increased customer satisfaction and loyalty, as well as the impact on work processes and employee productivity.

Keywords: AI analytics, personalization, service automation, customer experience, behavior prediction, chatbots, virtual assistants, T-Bank, SberBank, neural network technologies, service efficiency, customer loyalty.

УДК 331.5

ВЛИЯНИЕ LLM МОДЕЛЕЙ НА РЫНОК ТРУДА

Ощепков Виталий Андреевич

ФГБОУ ВО «Уральский государственный экономический университет»,
620000, Россия, Екатеринбург, ул.8 Марта, 62
vitalik30.05@mail.ru

В статье представлен разбор влияния LLM моделей и генеративного искусственного интеллекта на рынок труда. В работе разобраны сферы деятельности и примерный процент их автоматизации, а также влияние автоматизации на рабочие места.

Ключевые слова: LLM модели, искусственный интеллект, рынок труда, большая языковая модель, генеративный искусственный интеллект.

Введение. За последнее время произошёл резкий скачок развития генеративных систем искусственного интеллекта, что повысило спрос и интерес на них со стороны общественности. Сейчас с их помощью можно решать сложные задачи, так как были развиты такие аспекты систем, как увеличение параметров модели, совершенствование методик обучения, использование больших баз данных для обучения и улучшение работы с текстами на разных языках. Большие языковые модели хорошо себе зарекомендовали для решения задач, таких как классификация данных, перевод текстов, создание кода без использования специализированных архитектур или привязки данных к предметной области.

Большая языковая модель – это языковая модель, которая основана на архитектуре нейронных сетей с множеством параметров, обученной на большом количестве неразмеченного текста с использованием обучения без учителя. LLMмодели появились в 2018 году и применяются для решения широкого

спектра задач. Основными представителями данных систем являются GPT-3 и GPT-4, а на отечественном рынке – GigaChat и YandexGPT [3].

Существует обширный пласт литературы, который посвящён влиянию искусственного интеллекта и технологий автоматизации на рынок труда. Исследования в области автоматизации процессов труда выявили, что технический прогресс повышает спрос на квалифицированную рабочую силу по сравнению с неквалифицированной. Данные исследования расширили путём изучения влияния автоматизации на рутинную работу. Результаты исследований показали, что сотрудники, которые заняты рутинными задачами, более подвержены вытеснению. Исторически сложилось так, что автоматизация рабочих процессов приводила к экономическому неравенству и потере рабочих мест [2].

Недавние исследования в области рынков труда показали, что стремительное развитие LLM-моделей может значительно повысить производительность труда низко квалифицированных работников при выполнении однотипных задач по сравнению с сотрудниками с более высокой квалификацией [1]. Однако многие вопросы, касательно спроса на рабочую силу, заработную плату и качества рабочих мест по мере более широкого внедрения LLM-моделей до сих пор остаются без ответа. Поэтому целью данной статьи является изучение влияния больших языковых моделей на рынок труда.

Исследование предметной области. В ноябре 2023 года LinkedIn провели исследование «The Future of Work Report: AI at Work» в котором опросили один миллиард сотрудников и 67 миллионов компаний. По результатам исследования выявили, что с декабря 2022 по сентябрь 2023 год количество обсуждения касательно искусственного интеллекта выросло на 70% и 55% опрошенных людей испытывают изменения в своей рабочей деятельности из-за развития искусственного интеллекта [5]. Так как искусственный интеллект и LLM-модели, в частности, активно развиваются, то необходимо понимание, как они могут повлиять на рынок труда. Это поможет компаниям и сотрудникам адаптироваться к изменяющемуся рынку и оставаться в нём конкурентоспособными.

В марте 2023 года крупнейший инвестиционный банк США Goldman Sachs провёл аналитику касательно влияния искусственного интеллекта на экономический рост. Банк выделяет три основных различия генеративного искусственного интеллекта по сравнению с аналитическими системами [4]:

- Их можно использовать для различных задач, а не только для специализированных;
- Они способны генерировать новые результаты, похожие на человеческие, а не просто описывать или интерпретировать существующую информацию;
- Они имеют доступный интерфейс, через который искусственный интеллект может распознавать естественный язык, изображения, аудио, видео и реагировать на это, выдавая те же форматы информации.

Из данных особенностей следует, что генеративный искусственный интеллект способен создавать информацию, которая будет неотличима от информации, созданной человеком, и может разрушить барьер в общении между людьми и машинами.

Для того чтобы оценить масштаб эффекта от использования LLMмоделей на рынке труда, GoldmanSachs использовали сведения из бесплатной онлайн базы данных O*NET, которая содержит данные о профессиональных характеристиках и информацию о требованиях к работникам по всей экономике США. В системе описаны профессии с точки зрения требуемых знаний, навыков и способностей. Из базы O*NET GoldmanSachs выделили несколько видов деятельности, которые подвержены автоматизации с помощью искусственного интеллекта.

Затем было вычислено средневзвешенное значение важности и сложности основных рабочих задач для каждой профессии и произведена оценка доли общей рабочей нагрузки, которую LLMмодели могут потенциально взять на себя. В данном исследовании было обнаружено, что примерно две трети профессий в США подвергаются некоторой степени автоматизации со стороны LLMмоделей, в которых 25-50% рабочей нагрузки могут быть переданы на обработку искусственным интеллектом. По результатам исследований (рис. 1) четверть текущих рабочих задач может быть автоматизирована. Больше всего этому подвержены профессии, связанные с административными (46%) и юридическими (44%) работами. Меньше всего автоматизации подвержены профессии, связанные с применением физического труда, такие как строительство (6%) и техническое обслуживание (4%) [4].



Рис. 1. Доля профессиональных сфер деятельности, подверженных автоматизации

Представленные оценки показывают, что большая доля занятости может быть автоматизирована с помощью применения генеративного искусственного интеллекта и LLM моделей. Хотя влияние искусственного интеллекта на рынок труда, вероятно, будет значительным, большинство рабочих мест и отраслей лишь частично подвержены автоматизации и, таким образом, с большей вероятностью будут дополнены, а не заменены искусственным интеллектом.

Закключение. Большая доля автоматизации профессиональных сфер деятельности с помощью генеративного искусственного интеллекта повышает по-

тенциал для роста производительности труда, который ведёт к увеличению глобального объёма производства. Существует два основных направления, через которые автоматизация с помощью искусственного интеллекта может повысить глобальный ВВП.

Во-первых, большинство работников, которые заняты в профессиях частично подверженных автоматизации, после внедрения искусственного интеллекта, скорее всего, направят часть своих освободившихся возможностей на деятельность, которая увеличит объём производства.

Академические исследования подтверждают, что работники компаний, которые первыми внедряют искусственный интеллект, испытывают более высокий рост производительности труда после внедрения, при этом оценки обычно предполагают изменения на 2-3% в год [4]. Хотя различия в возможностях генеративного искусственного интеллекта по сравнению с более ранними образцами затрудняют экстраполяцию этих результатов, но они явно указывают на то, что толковое применение LLM моделей может способствовать экономически значимому росту производительности.

Во-вторых, ожидается, что многие сотрудники, уволенные из-за процессов автоматизации, в конечном итоге будут трудоустроены повторно и, следовательно, увеличат общий объём производства в новых профессиях. Новые профессии возникнут либо непосредственно из-за внедрения LLM моделей, либо в ответ на более высокий уровень совокупного и трудового спроса, вызванного ростом производительности, за счёт оставшихся после автоматизации работников.

Библиографический список

1. Acemoglu, Daron and Pascual Restrepo. Automation and new tasks: How technology displaces and reinstates labor // Journal of Economic Perspectives 33, no. 2 (2019): 3-30.
2. Autor, David, Caroline Chin, Anna M. Salomons, and Bryan Seegmiller. New Frontiers: The Origins and Content of New Work // National Bureau of Economic Research, No. w30389 (2022).
3. Назаров Д. М., Бегичева С. В. Применение больших языковых моделей в образовательном процессе // Бизнес. Образование. Право. 2024. № 3(68). С. 430–436. DOI: 10.25683/VOLBI.2024.68.1057.
4. GoldmanSachs – The Potentially Large Effects of Artificial Intelligence on Economic Growth. [Электронный ресурс]. Режим доступа: <https://www.gspublishing.com/content/research/en/reports/2023/03/27/d64e052b-0f6e-45d7-967b-d7be35fabd16.html>
5. LinkedIn – Future of work report. [Электронный ресурс]. Режим доступа: <https://economicgraph.linkedin.com/research/future-of-work-report-ai>

THE IMPACT OF LLM ON THE LABOR MARKET

Vitaly Andreevich Oshchepkov

Ural State University of Economics,
Str. 8 Marta, 62, Yekaterinburg, Russia, 620000
vitalik30.05@mail.ru

The article presents an analysis of the impact of LLM models and generative artificial intelligence on the labor market. The work analyzes the areas of activity and the approximate percentage of their automation, as well as the impact of automation on jobs.

Keywords: LLM, artificial intelligence, labor market, large language model, generative artificial intelligence.

ФУНКЦИЯ ПОТЕРЬ QUANTILE LOG COSH В РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЯХ И ВОССТАНОВЛЕННАЯ ВОЛАТИЛЬНОСТЬ: ИННОВАЦИОННЫЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ ВОЛАТИЛЬНОСТИ

Патласов Дмитрий Александрович

Пермский государственный национальный исследовательский университет,
614068, Россия, г. Пермь, ул. Букирева, 15
dmitriypatlasov@gmail.com

В статье рассматривается модификация функции потерь Log Cosh для задачи предсказания волатильности, названная Quantile Log Cosh. Эта функция усиливает штраф за ошибки модели на данных выше 75-го квантиля. Предполагается, что такая модификация повысит точность моделей на валидационных и тестовых данных. Также исследуется гипотеза, что восстановленная волатильность является наиболее значимым фактором при прогнозировании реализованной волатильности на рынке США. В исследовании применяются модели LSTM, GRU, LightGBM, SVM и ARIMAX. Результаты показывают, что Quantile Log Cosh улучшает точность LSTM и GRU, а восстановленная волатильность оказывается важным экзогенным фактором.

Ключевые слова: прогнозирование, нейронные сети, машинное обучение, волатильность, финансовые рынки.

Введение. Фондовый рынок играет ключевую роль в мировой экономике, влияя на финансовую стабильность стран. В условиях высокой неопределенности прогнозирование волатильности становится важным инструментом для участников рынка. В данной статье исследуется задача предсказания волатильности с использованием теоремы восстановления Росса и модифицированной функции потерь Quantile Log Cosh.

Теорема Росса позволяет получить истинное распределение вероятностей доходности рынка на основе данных опционов, что дает возможность рассчитывать премию за риск, восстановленную волатильность и другие показатели. Восстановленная волатильность, аппроксимирующая стандартное отклонение на основе истинного распределения, рассматривается как важный предсказательный фактор.

Также предложена модификация функции потерь Log Cosh, усиливающая штраф за ошибки в области высоких значений волатильности (выше 75-го квантиля), что повышает точность прогнозов на нестабильных рынках.

Исследование выдвигает две гипотезы:

Модификация Quantile Log Cosh улучшит точность моделей на валидационных и тестовых данных.

Восстановленная волатильность окажется значимым фактором при прогнозировании реализованной волатильности.

Предполагается, что эти методы могут повысить качество прогнозов, обеспечивая более точные данные для инвесторов и регуляторов.

Постановка задачи

В статье рассматривается прогнозирование реализованной волатильности индекса S&P 500 на основе восстановленной волатильности. Реализованная волатильность ($\sigma_t^{realized}$) измеряется по фактическим ценам закрытия фьючерсов, тогда как восстановленная волатильность ($\sigma_t^{realized}$) рассчитывается с использованием теоремы восстановления Росса, применяя данные по опционам.

Формула для расчета реализованной волатильности:

$$\sigma_t^{realized} = \sqrt{\frac{1}{N} \sum_{i=1}^n \left(\ln \left(\frac{S_t}{S_{t-1}} \right) \right)^2}, \quad (1)$$

где

RV_t – реализованная волатильность в момент времени t ;

n – количество наблюдений;

S_t – значение индекса S&P 500 (пункты) в момент времени t .

Теорема Росса помогает извлекать истинные вероятности из рыночных данных опционов. Связь между риск-нейтральными (π^*) и истинными вероятностями (f) описывается через маргинальные полезности потребления и безрисковую ставку. Истинные вероятности позволяют оценивать будущие состояния рынка и риск.

Процедура извлечения плотностей включает:

Определение риск-нейтральной плотности через рыночные цены опционов.

Восстановление истинной плотности с использованием маргинальных полезностей.

Применение Марковских цепей для расчета переходных вероятностей рынка.

Восстановленная волатильность определяется как стандартное отклонение плотности, полученной на основе этих переходных вероятностей.

Подробнее о теореме можно узнать из работ Росса (2015) и других исследователей, таких как Bakshi, Carr и Jackwerth.

Результаты исследования. Результаты обучения моделей для прогнозирования волатильности S&P 500 представлены в табл. 1. Оценка производительности проводилась по четырем метрикам: MSE, MAE, R2 и MAPE.

Сравнение производительности различных моделей и функций потерь на валидационной и тестовой выборках

Модель и вид функции потерь	MSE	MAE	R ²	MAPE
Валидационная выборка				
LSTM (quantile log cosh)	0,0000	0,0008	0,9994	0,0011
LSTM (log cosh)	0,0000	0,0046	0,9994	0,0011
GRU (quantile log cosh)	0,0000	0,0011	0,9989	0,0016
GRU (log cosh)	0,0000	0,009	0,9989	0,0016
ARIMAX(1,0,3)	0,0014	0,0226	-0,0185	0,0370
Light GBM	0,0014	0,0221	0,0037	0,0362
SVM	0,0014	0,0230	-0,0168	0,0372
Тестовая выборка				
LSTM (quantile log cosh)	0,0000	0,0014	0,9895	0,0027
LSTM (log cosh)	0,0002	0,0063	0,9346	0,0104
GRU (quantile log cosh)	0,0000	0,0018	0,9863	0,0033
GRU(log cosh)	0,0001	0,0017	0,9799	0,0033
ARIMAX(1,0,3)	0,0009	0,0191	-0,0272	0,0314
Light GBM	0,0009	0,0183	-0,0020	0,0302
SVM	0,0009	0,0195	-0,0282	0,0319

Основные выводы:

LSTM с Quantile Log Cosh показала наилучшие результаты на валидационных и тестовых данных по всем метрикам, что подтверждает эффективность этой функции потерь для задачи прогнозирования волатильности.

GRU с Quantile Log Cosh также продемонстрировала хорошие результаты, особенно на тестовой выборке, уступая LSTM.

Модели Light GBM, ARIMAX и SVM значительно хуже по всем метрикам, с отрицательными значениями R², что указывает на их низкую предсказательную силу.

Графики квантильных ошибок (рис. 1-2) показывают, что Quantile Log Cosh обеспечивает более низкие ошибки по сравнению с Log Cosh, особенно на высоких квантилях. Это подтверждает преимущество Quantile Log Cosh для обеих моделей, особенно в условиях экстремальной волатильности.




Рис. 1. Квантильные ошибки модели LSTM с разными функциями потерь




Рис. 2. Квантильные ошибки модели GRU с разными функциями потерь

Таким образом, использование восстановленной волатильности как единственного фактора обеспечивает более точные прогнозы, тогда как дополнительные признаки снижают точность из-за увеличения шума.

Заключение. В статье рассматривается задача прогнозирования реализованной волатильности индекса S&P 500 на основе восстановленной волатильности, оцененной с помощью теоремы восстановления Росса. Для улучшения точности предсказаний предложена модифицированная функция потерь Quantile Log Cosh, которая усиливает штраф за ошибки на высоких квантилях. В исследовании выдвигаются две гипотезы: 1) Quantile Log Cosh улучшит точность моделей LSTM и GRU по сравнению с классической функцией Log Cosh, 2) восстановленная волатильность является ключевым фактором для прогнозирования реализованной волатильности.

Тестирование моделей (LSTM, GRU, LightGBM, SVM, ARIMAX) подтверждает, что Quantile Log Cosh повышает точность предсказаний для LSTM и GRU, а восстановленная волатильность – наиболее значимый признак. Результаты подчеркивают важность точного прогнозирования волатильности для разработки торговых стратегий. В будущем планируется использование этих предсказаний для построения стратегий с применением методов обучения с подкреплением.

Библиографический список

1. Amir A. et al. Can we recover the cover? //Algorithmica. – 2019. – Т. 81. – №. 7. – С. 2857-2875.
2. Anamizu K. Ross Recovery under the Tree Model and Its Application to Risk Management : diss. – Tokyo Metropolitan University, 2018.
3. Audrino F., Huitema R., Ludwig M. An empirical implementation of the Ross recovery theorem as a prediction device //Journal of Financial Econometrics. – 2021. – Т. 19. – №. 2. – С. 291-312.
4. Bakshi G., Chabi-Yo F., Gao X. A recovery that we can trust? Deducing and testing the restrictions of the recovery theorem //The Review of Financial Studies. – 2018. – Т. 31. – №. 2. – С. 532-555.
5. Barron, J. T. (2019). «A General and Adaptive Robust Loss Function». Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 4331-4339.
6. Borovička J., Hansen L. P., Scheinkman J. A. Misspecified recovery //The Journal of Finance. – 2016. – Т. 71. – №. 6. – С. 2493-2544.
7. Carr P., Yu J. Risk, return, and Ross recovery //The Journal of Derivatives. – 2012. – Т. 20. – №. 1. – С. 38-59.
8. Corsi F. et al. The volatility of realized volatility //Econometric Reviews. – 2008. – Т. 27. – №. 1-3. – С. 46-78.
9. Gagnon M. H., Power G. J., Toupin D. Forecasting market index volatility using Ross-recovered distributions //Quantitative Finance. – 2022. – Т. 22. – №. 2. – С. 255-271.
10. Gunnarsson E. S. et al. Prediction of realized volatility and implied volatility indices using AI and machine learning: A review //International Review of Financial Analysis. – 2024. – С. 103221.
11. Hochreiter, S., & Schmidhuber, J. (1997). «Long Short-Term Memory». Neural Computation, 9(8), 1735-1780.
12. Huber, P. J. (1964). «Robust Estimation of a Location Parameter». The Annals of Mathematical Statistics, 35(1), 73-101.
13. Jackwerth J. C., Menner M. Does the Ross recovery theorem work empirically? //Journal of Financial Economics. – 2020. – Т. 137. – №. 3. – С. 723-739.
14. Ke, G., et al. (2017). «LightGBM: A Highly Efficient Gradient Boosting Decision Tree». Advances in Neural Information Processing Systems, 30, 3146-3154.
15. Qin L., Linetsky V., Nie Y. Long forward probabilities, recovery, and the term structure of bond risk premiums //The Review of Financial Studies. – 2018. – Vol. 31. – No. 12. – pp. 4863-4883.
16. Ross S. The recovery theorem //The Journal of Finance. – 2015. – Т. 70. – №. 2. – С. 615-648.

THE QUANTILE LOG COS LOSS FUNCTION IN RECURRENT NEURAL NETWORKS AND RECOVERED VOLATILITY: INNOVATIVE METHODS FOR VOLATILITY PREDICTION

Dmitry A. Patlasov

Perm State National Research University,
Bukireva str., 15, Perm, Russia, 614068
dmitriypatlasov@gmail.com

The article discusses a modification of the Log Cosh loss function for the volatility prediction problem, called Quantile Log Cosh. This function increases the penalty for model errors on data above the 75th quantile. It is assumed that such a modification will increase the accuracy of models based on validation and test data. The hypothesis is also being investigated that restored volatility is the most significant factor in predicting realized volatility in the US market. The LSTM, GRU, LightGBM, SVM and ARIMAX models are used in the study. The results show that the Quantile Log Cosh improves the accuracy of LSTM and GRU, and the restored volatility turns out to be an important exogenous factor.

Keywords: forecasting, neural networks, machine learning, volatility, financial markets.

УДК 004.9:338.24

ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ТРАНСФОРМАЦИЮ БИЗНЕС-МОДЕЛЕЙ

Савин Сергей Владимирович,

Мурзин Антон Дмитриевич,

ФГАОУ ВО «Южный федеральный университет»,
344090, Россия, г. Ростов-на-Дону, пр. Стачки, 200/1, к. 210А
rostovs@list.ru, admurzin@sfedu.ru

Исследование посвящено изучению влияния искусственного интеллекта (ИИ) на создание и трансформацию бизнес-моделей в цифровой экономике. Новизна работы заключается в детальном анализе трансформации основополагающих элементов этих моделей. Особое внимание уделено методике оценки эффективности внедрения ИИ, включая расчет показателя возврата на инвестиции (ROI) и анализ снижения операционных затрат. Рассматриваются перспективы полной автоматизации бизнес-процессов на основе ИИ, а также прогнозируются её экономические выгоды и потенциальные вызовы. Исследование подчеркивает необходимость инвестиций в технологии и пересмотра существующих бизнес-моделей для успешной ИИ-интеграции.

Ключевые слова: Искусственный интеллект, бизнес-модели, цифровая экономика, автоматизация, цифровизация.

Введение. Согласно отчету McKinsey (2023) свыше 70% коммерческих организаций уже внедрили цифровые технологии в свои процессы, что позволило не только оптимизировать затраты, но и ускорить адаптацию к изменениям в рыночной среде [1].

Экономические субъекты, активно применяющие ИИ-технологии, добиваются значимых успехов в таких сферах как автоматизация производства, менеджмент цепочек поставок и персонализация клиентских предложений.

Согласно данным Accenture (2023), 98% руководителей ожидают, что ИИ-технологии станут основой бизнес-стратегий в ближайшие годы, обеспечивая подготовку персонализированных предложений и создание новых цифровых продуктов [2]. Такие известные корпорации как Amazon и Netflix активно используют ИИ-инструментарий для анализа пользовательского поведения и персонализации контента, что способствует росту продаж и повышает удержание клиентов.

Таким образом, внедрение ИИ не только способствует оптимизации текущих организационных процессов, но и становится условием формирования новых схем осуществления бизнес-деятельности, позволяя компаниям быстрее адаптироваться к изменениям и эффективно реагировать на вызовы современного рынка [3].

Влияние ИИ на бизнес-модели.

Рассмотрим схемы ведения бизнес-деятельности, получившие развитие благодаря внедрению ИИ.

Платформенные модели – один из ярких примеров успешной интеграции ИИ в бизнес-модели, отражающих развитие платформ, основанных на данных, таких как Amazon и Airbnb. Эти корпорации используют ИИ для анализа крупных информационных массивов, что позволяет им оптимизировать взаимодействие между покупателями и продавцами, улучшать персонализацию предложений и повышать эффективность рекомендаций. Так, Airbnb, опирается на алгоритмы машинного обучения для динамического ценообразования, что позволяет автоматически корректировать стоимость аренды жилья в зависимости от спроса, сезонных изменений и иных переменных.

Модели подписок. Рынок подписочных услуг также активно эксплуатирует ИИ-инструментарий для создания персонализированного клиентского опыта. Например, такие предприятия как Spotify и Netflix опираются на алгоритмы, анализирующие пользовательское поведение для создания персонализированных рекомендаций контента, что помогает им удерживать клиентов. Подписочные бизнес-модели уже продемонстрировали свою успешность, в частности, согласно данным Zuora, доходы компаний, использующих такие подписочные подходы, растут в 6 раз быстрее по сравнению с традиционными вариантами [4].

Модели на основе данных и алгоритмов ИИ. Предприятия, опирающиеся на подходы к работе, в которых информация и ИИ выступают как ключевые активы, также демонстрируют быстрый рост. Например, Tesla использует ИИ для обработки сведений, получаемых от автопилота, что позволяет не только улучшать функциональность автомобилей, но и развивать экосистему вокруг автономных транспортных средств.

Специфике изменений бизнес-моделей можно увидеть в таблице ниже.

Специфика изменений

Элемент бизнес-модели	Описание изменений с ИИ
Создание ценности	ИИ используется для анализа данных и создания новых продуктов. Пример – Tesla, улучшающая функциональность автомобилей и развивающая экосистему автономных транспортных средств с использованием ИИ [8], [9].
Доставка ценности	ИИ оптимизирует цепочки поставок и складские операции. Пример – Amazon, сокращающий издержки на 20-30% и ускоряющий доставку товаров с помощью ИИ [9].
Монетизация ценности	ИИ помогает создавать новые модели доходов. Пример – Spotify, использующая ИИ для персонализации музыкальных рекомендаций. Это увеличило доходы от подписок и рекламы, что позволило компании достичь роста выручки на 16% за счет роста числа премиум-подписчиков [9].

Таким образом, можно заключить, что ИИ трансформирует традиционные подходы к предпринимательской деятельности, создавая новые возможности для более точного прогнозирования спроса, персонализации продуктов и оптимизации доставки ценности.

Проблемы и вызовы.

1. Проблема доверия к ИИ-системам. ИИ-алгоритмы зачастую настолько сложны, что их решения могут казаться «черным ящиком» даже для опытных квалифицированных пользователей. Так, в банковском секторе рекомендации в части решений по кредитованию, предлагаемые ИИ, могут быть непонятны сотрудникам, что снизит их доверие к ИИ-системам [9].

2. Риск потери контроля над ИИ-системами возрастает по мере автоматизации бизнес-процессов. Например, в производственных компаниях, таких как Siemens, ИИ управляет процессами без вмешательства человека, что вызывает опасения по поводу безопасности и ответственности.

3. Этические аспекты взаимодействия обостряются на фоне развивающегося взаимодействия человека с ИИ. Морально-этические вопросы требуют более строгих стандартов регулирования и внедрения инструментария аудита ИИ [10].

Существуют несколько интересных примеров. **Amazon.** пытался автоматизировать процессы найма с помощью системы на базе ИИ. Цель заключалась в том, чтобы ИИ-система анализировала резюме кандидатов и рекомендовала лучших из них. Однако она проявила гендерные предубеждения, так как была обучена на данных о доминирующем числе мужчин на инженерных позициях. Это привело к тому, что алгоритм стал дискриминировать женщин, что, в свою очередь, вынудило Amazon отказаться от проекта [11].

А **Microsoft** запустил чат-бота под названием Tay, предназначенный для общения в Twitter. Tay обучался на данных, полученных от пользователей, и

должен был улучшать свои навыки общения. Однако уже через 24 часа после запуска интернет-тролли начали направлять коммуникацию с ботом в неправильное русло, из-за чего он стал создавать оскорбительные и неприемлемые сообщения. Проект был быстро закрыт, продемонстрировав опасность публичного обучения ИИ без тщательного контроля [11].

Эти примеры наглядно отражают значимость тщательного тестирования и мониторинга ИИ-систем, особенно в сферах, где «ставки высоки», таких как рекрутинг и коммуникации.

Экономическая оценка внедрения ИИ.

Для оценки эффективности интегрирования ИИ в бизнес-деятельность стоит учитывать несколько ключевых факторов. Во-первых, это показатель ROI (возврат на инвестиции):

$$ROI = \frac{(\text{Доход от ИИ} - \text{Затраты на его внедрение})}{\text{Затраты на внедрение}} \quad (1)$$

Этот показатель позволяет оценить экономическую целесообразность инвестиций в ИИ-технологии, используемые конкретным субъектом хозяйствования.

Важным фактором выступает также снижение операционных затрат, определяемое как разница между затратами до и после внедрения ИИ-механизмов.

Повышение производительности оценивается по увеличению скорости исполнения задач и снижению времени на операции. Удовлетворенность клиентов оценивается по показателям роста лояльности и улучшения клиентского опыта благодаря персонализации и оптимизации взаимодействия с потребителями.

Этапы оценки эффективности включают:

- диагностику состояния экономического субъекта до внедрения ИИ-технологий;
- анализ краткосрочных и долгосрочных эффектов,
- а также регулярный мониторинг результатов с целью корректировки бизнес-процессов для последующего повышения эффективности.

Инвестиции в ИИ-технологии демонстрируют разные уровни рентабельности в зависимости от специфики конкретной отрасли.

Согласно данным **IDC** компании, внедрившие ИИ-инструменты, получают возврат на уровне порядка \$3.5 на каждый вложенный доллар, что соответствует 250% ROI.

В финансовом секторе банки и страховые компании используют ИИ-инструментарий для автоматизированной обработки данных, риск-менеджмента и повышения качества клиентского обслуживания [14].

Производственные компании, такие как **Siemens**, благодаря интегрированию механизмов предиктивного обслуживания промышленного оборудования сократили количество непредвиденных его поломок на 20-30%, что сократило затраты на ремонт и обслуживание, обеспечив более высокий уровень показателя возврата инвестиций [24].

В сфере электронной коммерции и ритейла такие компании как **Amazon** демонстрируют ROI на уровне порядка 10-20% за счет оптимизации цепочек поставок, улучшения логистики и сокращения избыточных запасов [15].

Полная автоматизация бизнес-процессов на базе ИИ представляет собой следующий этап развития многих отраслей. Прогнозы показывают, что к 2030 году внедрение ИИ в автоматическое исполнение производственных процессов организаций повысит их операционную эффективность на 20-30%, благодаря предиктивному обслуживанию, робототехнике и оптимизации производственных процессов [16].

В ритейле реализация автоматизированного подхода к осуществлению операций уже снижает запасы на складах на 10-20%, что, в свою очередь, увеличивает прибыль компаний на 5-10% [26].

В финансовом секторе автоматизированный менеджмент рисков и анализ данных позволяют снизить операционные затраты финансовых организаций на 20-25%, увеличивая их прибыль на 15-20% [17].

Прогнозируется, что к 2030 году ИИ-системы смогут заместить до 50% ручных процессов в таких отраслях как производство, логистика и финансы. Это приведет к значительным изменениям в структуре расходов компаний и на рынке труда [18].

Представляется, что полная автоматизация на базе ИИ откроет новые возможности для роста и повышения конкурентоспособности субъектов экономики, однако это потребует значительных инвестиций и пересмотра существующих бизнес-моделей.

Библиографический список

1. McKinsey & Company. The state of AI in 2023: Generative AI's breakout year // McKinsey & Company. 2023. URL: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2023-generative-ais-breakout-year> (дата обращения: 11.09.2024).
2. Accenture. Technology Vision 2023: Generative AI to Usher in a Bold New Future for Business // Accenture. 2023. URL: <https://newsroom.accenture.com/news/2023/accenture-technology-vision-2023-generative-ai-to-usher-in-a-bold-new-future-for-business-merging-physical-and-digital-worlds> (дата обращения: 05.09.2024).
3. Gartner. The biggest new technology trends in 2024 // Gartner. 2024. URL: <https://www.gartner.com/en/information-technology/insights/top-technology-trends> (дата обращения: 11.09.2024).
4. Zuora. Subscription Businesses Outpace S&P 500 Revenues Nearly 6X Amid Pandemic. URL: <https://www.businesswire.com/news/home/20200923005296/en/> (дата обращения: 07.09.2024).
5. Simon-Kucher. (2024). Value Monetization in the Age of AI. URL: <https://www.simon-kucher.com>. (дата обращения: 07.09.2024)
6. McKinsey & Company. (2023). How AI can deliver real value to companies. URL: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/how-artificial-intelligence-can-deliver-real-value-to-companies> (дата обращения: 11.09.2024)
7. Siemens. Predictive maintenance at scale is entering the mainstream. Siemens Blog, 2023. URL: <https://blog.siemens.com/2023/07/predictive-maintenance-at-scale-is-entering-the-mainstream/> (дата обращения: 07.09.2024).

8. Rockwell Automation. AI Predictive Maintenance Solutions Help Reduce Downtime. Rockwell Automation, 2023. URL: <https://www.rockwellautomation.com/en-us/company/news/press-releases/ai-predictive-maintenance.html> (дата обращения: 07.09.2024).
9. Wang, T. Complexity-Driven Trust Dynamics in Human–Robot Interactions: Insights from AI-Enhanced Collaborative Engagements. MDPI, 2023. URL: <https://www.mdpi.com>
10. Shojaei, A. AI – The good, the bad, and the scary. Virginia Tech, 2023. URL: <https://eng.vt.edu>
11. Lexalytics. Stories of AI Failure and How to Avoid Similar AI Fails. URL: www.lexalytics.com (дата обращения: 07.09.2024).
12. Cloudera. *How AI is Reducing Operational Costs in Financial Services*. URL: www.cloudera.com (дата обращения: 07.09.2024).
13. NextDeveloper. *Reducing Operational Costs with AI-Powered Automation*. URL: <https://nextdeveloper.com/blog/reducing-operational-costs-with-ai-powered-automation> (дата обращения: 07.09.2024).
14. VentureBeat. *IDC Study: Businesses Report a Massive 3.5x Return on AI Investments*. URL: <https://venturebeat.com/ai/idc-study-businesses-report-a-massive-3-5x-return-on-ai-investments/> (дата обращения: 07.09.2024)
15. AiExponent. *How to Measure the Business Value of AI*. URL: www.aiexponent.com (дата обращения: 07.09.2024)
16. InsightAce Analytic. *AI in Industrial Automation Market Demanding Trends Analysis 2024-2031*. URL: www.insightaceanalytic.com (дата обращения: 07.09.2024).
17. Quixl AI. *The Present and Future of AI-Based Automation: A Roadmap for Business Leaders*. URL: <https://www.quixl.ai/blog/the-present-and-future-of-ai-based-automation-a-roadmap-for-business-leaders/> (дата обращения: 11.09.2024)
18. MetaDialog. *AI for Business Automation: Transforming Impact in 2024*. URL: <https://www.metadialog.com/blog/ai-for-business-automation-transforming-impact-in-2024/> (дата обращения: 07.09.2024)

THE ROLE OF ARTIFICIAL INTELLIGENCE IN CREATING NEW BUSINESS MODELS IN THE DIGITAL ECONOMY: FROM DIGITALIZATION TO FULLY AUTOMATED SOLUTIONS

Sergey V. Savin

Anton D. Murzin,

Southern Federal University,

Stachki Ave, 200/1, Office 210A, Rostov-on-Don, Russia, 344090

rostovs@list.ru, admurzin@sfedu.ru

This article explores the impact of artificial intelligence (AI) on the creation and transformation of business models in the digital economy. The novelty lies in the detailed analysis of the transformation of key elements of these models. Special attention is given to evaluating the effectiveness of AI implementation, including ROI calculations and operational cost reduction analysis. The prospects of full AI-based business process automation are considered, along with its economic benefits and potential challenges. The study emphasizes the need for investment in technology and a revision of existing business models for successful AI integration.

Keywords: Artificial intelligence, business models, digital economy, automation, digitalization.

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ ФАКТОРОВ, ВЛИЯЮЩИХ НА ОБЪЕМ ПРОДАЖ ТОВАРОВ НА МАРКЕТПЛЕЙСЕ

Варнухов Артем Юрьевич

Уральский государственный экономический университет,
620144, Россия, г. Екатеринбург, ул. 8 марта, 62
vudyart@gmail.com

Процесс покупки и продажи товара на маркетплейсе характеризуется рядом отличий от традиционного способа совершения покупок. Во-первых, все взаимодействие между покупателями и продавцами происходит исключительно в рамках цифровой платформы. Во-вторых, маркетплейсы аккумулируют широкий ассортимент товаров от различных поставщиков и большое количество потенциальных покупателей. Это, в совокупности, приводит к формированию ряда факторов, обусловленных моделью взаимодействия на маркетплейсе, которые могут оказывать влияние на объем продаж. В данной статье рассматривается возможность использования методов машинного обучения для определения степени значимости внутренних факторов, которые не связаны с товарными характеристиками. Представляются результаты разведочного анализа данных, а также выявленные зависимости.

Ключевые слова: маркетплейс, машинное обучение, анализ данных, разведочный анализ, внутренние факторы продаж, оптимизация продаж.

Введение. Из представленных данных в отчете «Интернет-торговля в России 2024», подготовленного аналитическим агентством Data Insight [1], следует, что объем рынка онлайн коммерции в России составил 7,9 трлн. рублей, продемонстрировав рост в 48% по отношению к предыдущему отчетному периоду. Под электронной коммерцией авторы исследования понимают любую покупку товаров по модели B2C, совершенную потребителями при помощи сайта или через мобильное приложение. Одним из ключевых драйверов роста рынка электронной коммерции являются продажи товаров, которые осуществляются на маркетплейсах. Маркетплейсы представляют собой частный случай платформенной бизнес-модели [2]. Концепция платформ была впервые сформулирована в 2000-х годах и основана на создании единой экосистемы, в которой участники могут взаимодействовать между собой создавая ценность [3]. Платформы позволяют объединять несколько различных групп участников, в случае с маркетплейсами – продавцов и покупателей, обеспечивая удобство взаимодействия и упрощая процесс совершения покупок [4,5]. Платформы оперируют на двусторонних рынках и обладают рядом существенных отличий от традиционных бизнес-моделей: сетевые эффекты, посредническая роль, а также высокая степень интеграции с цифровыми технологиями [6, 7]. Маркетплейсы предоставляют продавцам множество преимуществ, в том числе доступ к большой и разнообразной клиентской базе, что позволяет повысить широту географического охвата и увеличить количество заключенных сделок. Они упрощают процесс продаж благодаря единой экосистеме и встроенным ин-

струментам для управления заказами, обработки платежей и логистической поддержке. Кроме того, маркетплейсы создают для продавцов условия для легкого масштабирования бизнеса, возможности для работы на международных рынках, а также снижают барьеры, что, в конечном итоге, позволяет предприятиям легко выходить на рынок и расширять свой охват без значительных инвестиций. Вместе с тем, работа на маркетплейсе создает для продавцов новые сложности, которые не встречаются при традиционной продаже товара в офлайн. В частности, изменяется модель взаимодействия и поиска товара покупателями. Присутствие большого количества продавцов на маркетплейсе приводит к формированию широкого ассортиментного предложения, собранного в одном месте. И покупателю необходимо найти интересующий его товар среди множества других предложений, а также определить какое предложение является наилучшим выбором из имеющихся вариантов. Для решения этой задачи маркетплейсы обеспечивают покупателей встроенной поисковой системой, информационными карточками товара, возможностью просмотра отзывов и так далее. Эти аспекты взаимодействия и точки касания с товаром на маркетплейсе могут оказывать влияние на принятие решения о приобретении товара покупателем и вместе с тем оказываются фактически слабо связанными с непосредственными характеристиками товара.

Постановка задачи. Выявление и определение факторов, не связанных напрямую с характеристиками товара, влияющих на объем продаж и обусловленных особенностями реализации товара через маркетплейс, таким образом, оказывается важной задачей при прогнозировании объема спроса и выстраивания общей стратегии продаж на маркетплейсах. Для выявления факторов, которые могут оказывать влияние на объем продаж товара на маркетплейсе требуется выполнить следующие шаги:

- 1) Собрать исходные данные из открытых источников, провести предобработку и разведочный анализ;
- 2) Применить методы машинного обучения для формирования количественной оценки факторов влияния и оценить полученные результаты.

Сбор исходных данных из открытых источников, предобработка и разведочный анализ. Для проведения эксперимента было принято решение изучить данные о товарах, размещенных на торговой площадке Wildberries. В качестве основной товарной группы была выбрана категория «Футболки». Такой выбор обусловлен несколькими факторами: во-первых, товары в этой категории обладают определенной однородностью и минимальными эффектами брендинга; во-вторых, здесь представлено большое количество предложений от разных продавцов; и, в-третьих, категория характеризуется активной динамикой и высоким уровнем продаж. В результате было собрано 3113 примеров, каждая из которых содержит следующие поля: X1 –позиция в категории, X2 –количество складов, X3 –дней на сайте, X4 –отзывы, X5 –рейтинг, X6 –коэффициент карточки, X7 –цена, X8 –скидка, X9 –был в наличии, X10– количество фото, X11–видео, X12–количество продаж. Поскольку один и тот же товар может быть представлен в разных подгруппах, то параметр «позиция в категории» может иметь одинаковое значение для различных товаров. Параметр

«коэффициент карточки» отражает степень заполненности информации в карточке товара и был рассчитан с помощью метода взвешенных сумм и произведений. Параметр «был в наличии» отражает количество дней в месяце, по итогам которых товар имел положительные остатки на складах к концу дня. В процессе разведочного анализа данных из выборки были исключены записи, которые можно считать выбросами в контексте рассматриваемой задачи. Диаграммы распределения по некоторым признакам показаны на рис. 1.




Рис. 1. Диаграммы распределения некоторых признаков

Для оценки взаимосвязей между исследуемыми факторами сформируем тепловую карту, которая содержит коэффициенты попарной корреляции признаков (рис. 2).

На тепловой карте, рассматривая взаимосвязь с признаком «Кол-во продаж», можно заметить, что наибольший положительный коэффициент корреляции наблюдается с признаками «Количество складов», «Отзывы» и «Коэффициент карточки». Отрицательный коэффициент наблюдается с признаками «Цена» и «Позиция в категории».

Применение методов машинного обучения для формирования количественной оценки факторов влияния. Известно, что методы машинного обучения могут применяться для извлечения информации о значимости факторов и оценки их влияния на целевую переменную [8]. Например, модель линейной регрессии представляет собой линейную комбинацию признаков с соответствующими коэффициентами. Коэффициенты линейной регрессии отражают степень изменения зависимой переменной под воздействием конкретного фактора, при условии, что остальные факторы остаются неизменными. В данной работе для

оценки факторов применялся метод случайный лес. Основная идея этого метода заключается в использовании множества решающих деревьев, каждое из которых может иметь низкое качество, но их большое количество, обычно, способно обеспечить приемлемый итоговый результат. В качестве целевой переменной для задачи регрессии выступил признак «количество продаж». Исходные данные были случайным образом разделены на обучающую и тестовую группы в соотношении 80% на 20%. Построенная модель показала МАЕ на уровне 165. Результаты оценки важности признаков, по мнению модели, показаны на рис. 3.




Рис. 2. Тепловая карта с попарной корреляцией между признаками




Рис. 3. Оценка важности признаков

Заключение. Результаты проведенного эксперимента показали, что на объем продаж, в рамках модели взаимодействия продавца и покупателя на маркетплейсе, наибольшее влияние оказывают такие факторы, как: наличие отзывов и занимаемая товаром позиция в категории. Эти результаты согласуются с предположением, что покупатели просматривают только первые несколько страниц выдачи маркетплейса и уделяют особое внимание отзывам других потребителей.

Среди значимых факторов можно выделить количество складов у продавца, что может влиять на скорость доставки заказанных товаров и имеет важное значение для пользователей маркетплейса поскольку отражается на их удовлетворенности, степени доверия и общем впечатлении от покупок. Наименее значимым фактором оказался видеоконтент, что может указывать на достаточность другой информации, которая представлена в карточке товара. Таким образом, можно сделать вывод, что продавцам следует принимать во внимание характерные особенности как поведения покупателей, так и работы на маркетплейсах, поскольку они могут оказывать значимое влияние на объемы продаж товаров, а применение методов машинного обучения позволяет эффективно выявлять и оценивать такие факторы.

Библиографический список

1. DataInsight – Маркетинговое исследование «Интернет-торговля в России 2024» [Электронный ресурс]. Режим доступа: https://datainsight.ru/eCommerce_2023
2. Derave T. et al. Comparing digital platform types in the platform economy //International Conference on advanced information systems engineering. – Cham : Springer International Publishing, 2021. – С. 417-431.
3. Rochet J. C., Tirole J. Platform competition in two-sided markets //Journal of the european economic association. – 2003. – Т. 1. – №. 4. – С. 990-1029
4. Cozzolino A., Corbo L., Aversa P. Digital platform-based ecosystems: The evolution of collaboration and competition between incumbent producers and entrant platforms //Journal of Business Research. – 2021. – Т. 126. – С. 385-400.
5. Gleim M. R., Stevens J. L., Johnson C. M. Platform marketplaces: unifying our understanding of lateral exchange markets //European Journal of Marketing. – 2023. – Т. 57. – №. 1. – С. 1-28.
6. Lafuente E., Ács Z. J., Szerb L. Analysis of the digital platform economy around the world: A network DEA model for identifying policy priorities //Journal of Small Business Management. – 2024. – Т. 62. – №. 2. – С. 847-891.
7. Kenney M., Zysman J. The rise of the platform economy //Issues in science and technology. – 2016. – Т. 32. – №. 3. – С. 61.
8. Saarela M., Jauhiainen S. Comparison of feature importance measures as explanations for classification models //SN Applied Sciences. – 2021. – Т. 3. – №. 2. – С. 272.

THE USE OF MACHINE LEARNING METHODS TO DETERMINE THE FACTORS THAT AFFECT THE VOLUME OF SALES OF GOODS ON MARKETPLACE

Artem Ju. Varnukhov

Ural State University of Economics,
8 Marta str., 62, Yekaterinburg, Russia, 620144
vudyart@gmail.com

The process of buying and selling goods on the marketplace is characterized by a number of differences from the traditional way of making purchases. Firstly, all interaction between buyers and sellers takes place exclusively within the framework of the digital platform. Secondly, marketplaces accumulate a wide range of products from various suppliers and a large number of potential buyers. This together leads to the formation of a number of factors due to the interaction model on the marketplace, which can have an impact on sales volume. This article discusses the possibility of using machine learning methods to determine the degree of importance of internal factors that are not related to product characteristics. The results of the exploratory data analysis are presented, as well as the identified dependencies.

Keywords: marketplace, machine learning, data analysis, exploration analysis, internal demand factors, sales optimization.

УДК 519.2; 517.9; 004.8

НЕЙРОСЕТЕВОЙ АНАЛИЗ НЕЛИНЕЙНОЙ ДИНАМИЧЕСКОЙ МОДЕЛИ РЫНКА С ГИСТЕРЕЗИСОМ НА ОСНОВЕ АЛГОРИТМА ОЦЕНКИ ПОКАЗАТЕЛЯ ХЁРСТА НА МАЛЫХ ВЫБОРКАХ

Иванов Александр Иванович

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

Тарасов Дмитрий Викторович

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

Для описания рынка предложено использовать модель Гаммерштейна с входной линейной динамической частью и выходной гистерезисной нелинейностью. Если рассматривать входные данные модели Гаммерштейна как хаос («белый шум»), то участкам спада цен и подъема цен соответствуют разные импульсные переходные функции линейной динамической части модели. «Белый» и «окрашенный» шум – это характеристики энтропии наблюдаемых данных изменения цен. Оценка энтропии на малых выборках возможна, если энтропию оценивать сверточными нейронными сетями, например, опираясь на нейроны оценки эмпирического показателя Хёрста. Приведена связь классической энтропии с эмпирическим показателем Хёрста и показателем корреляционной сцепленности, анализируемых данных.

Ключевые слова: модель рынка, гистерезис, динамическая модель, разметка данных рынка, эмпирический показатель Хёрста.

Общие положения идентификации нелинейных динамических моделей. Линейные одномерные динамические модели могут быть достаточно точно описаны во временной области импульсной переходной функцией:

$$y(t) = \int_0^T h(\tau)x(t-\tau)d\tau, \quad (1)$$

где T – время памяти линейной динамической части модели; $h(\tau)$ – импульсная переходная функция модели.

В случае, если мы наблюдаем входной и выходной сигналы модели восстановить ее импульсную переходную функцию несложно [1, 2]. Применительно к анализу рынка задача усложняется тем, что мы можем наблюдать только отклик рынка в условиях его нестационарности как по его динамическим свойствам, так и по его нелинейным свойствам.

Кроме того, ситуация осложняется тем, что модель рынка должна учитывать его нестационарность [3]. Одним из ярких показателей нестационарности моделей рынка является периодическое переключение тренда рынка с «медвежьего» участка падения цен на «бычий» участок роста цен [4]. Брокеры на бирже придерживаются тактике продавать товар (акции) в конце «медвежьего» тренда, а покупать товары и акции желательно в конце «бычьего» тренда. Фактически брокеры зарабатывают свою часть прибыли на нелинейных эффектах петель гистерезиса, сглаживая колебания неустойчивости (не стационарности) состояний рынка [5]. Сглаживание колебаний состояний рынка чем-то напоминает рессору, которая, сглаживая колебания кузова автомобиля на плохой дороге, нагревается. В нашем же случае, брокер при сильной волатильности цен рынка хорошо зарабатывает, попутно участвуя в сглаживании колебаний цен на рынке.

Таким образом, нелинейная динамическая модель рынка может быть представлена моделью Гаммерштейна [6], состоящей из входного линейного динамического звена и выходной нелинейности с гистерезисом (рис. 1).




Рис. 1. Простейшая нелинейная динамическая модель рынка с выходной нелинейностью, имеющей петлю гистерезиса

Отметим, что при идентификации параметров модели рынка представляет интерес как ее линейные динамические свойства в виде импульсной переходной функции, так и ее нелинейные свойства, порождаемые петлями гистерезиса и, приносящие прибыль брокерам [4].

Линеаризация модели рынка при идентификации ее динамических параметров. Очевидно, что наличие гистерезисной нелинейности на выходе модели Гаммерштейна затрудняет идентификацию импульсной переходной функции ее входного линейного динамического звена. Для упрощения задачи выполним линеаризацию модели. Формально линеаризацию модели можно выполнить в ручном и/или автоматическом режиме разметки данных рынка на участки «быки»/«медведи». На рис. 2 приведен пример ручной разметки коле-

баний цен биткоина (BTC) в долларах США в мае-июне 2023 г. (данные взяты с сайта <https://www.binance.com>) [7].

Также разметку можно выполнить с использованием методов прогнозирования временных рядов и других финансовых инструментов [3]. Кроме того, нами был реализован практический курс лабораторных работ по изучению экономических временных рядов и моделированию разметки рынка с использованием такого эмпирического инструмента как показатель Хёрста [8] (рис. 3).




Рис. 2. Цены биткоина (BTC) в период с 8 мая по 6 июня 2023 г.

Очевидно, что по размеченным состояниям рынка на участки «быки»/«медведи» мы легко можем восстановить ломаную линию трендов $l(t)$. На рис. 2 такая ломаная линия представлена тремя участками. Если динамические свойства у модели Гаммерштейна (см. рис. 1) полностью отсутствуют (рынок не обладает инерцией), то импульсная переходная функция должна быть единичной при $\tau=0$ и принимать нулевые значения, когда $\tau \neq 0$. Только в этой ситуации входной «белый шум» $x(t)$ останется «белым шумом» пройдя сквозь без инерционный входной блок. Последнее означает, что сигнал на выходе линейного звена будет иметь равномерный спектр $Y(j\omega)$.




Рис. 3. Анализ экономического временного ряда

В частотной области свертка (1) превращается в произведение на комплексный коэффициент передачи линейного звена:

$$Y(j\omega) = H(j\omega) \cdot X(j\omega). \quad (2)$$

Если считать, что модель Гаммерштейна рынка возбуждается «белым шумом» $x(t)$, то передаточная функция $H(j\omega)$ должна описываться следующим приближением: $Y(j\omega) - L(j\omega) = H(j\omega) \cdot a$, где a – некоторый масштабный коэффициент.

Таким образом, удастся оценить частотные параметры функции коэффициента передачи входной динамической части модели Гаммерштейна и если это необходимо найти ее импульсную переходную функцию обратным преобразованием Фурье.

Приближенная оценка параметров гистерезисной нелинейности.

Следует отметить, что имитация гистерезиса может быть сформирована из четной и нечетной составляющих [9, 10]. В простейшем случае модель может быть сформирована из линейной нечетной составляющей и квадратичной четной составляющей:

$$\begin{cases} z = y, \\ z_{\text{Бык}} = y + b \cdot (y - 1)^2, \\ z_{\text{Мед}} = y - b \cdot (y - 1)^2, \end{cases} \quad (3)$$

где коэффициент параболы b вычисляются исходя из процента прибыли, полученной брокером на одном цикле гистерезиса.

Прибыль определяется соотношением площади цикла гистерезиса и квадрата, куда он вписан. На рис. 4 представлена программа на языке MathCAD, воспроизводящая симметричный гистерезис (3).

$$\begin{aligned} i &:= 0..200 & \text{int}_i &:= -1 + 0.01 \cdot i & z1_i &:= \text{int}_i & b &:= 0.5 \\ z3_i &:= z1_i + [1 - (z1_i)^2] \cdot b & z2_i &:= z1_i - [1 - (z1_i)^2] \cdot b \end{aligned}$$




Рис. 4. Модель симметричного гистерезиса, определяющего прибыль, получаемого брокером на одном цикле

Оценка эмпирического показателя Хёрста на малых выборках и его связь с энтропией данных рынка. Следует отметить, что динамика вариаций цен рынка, присутствие в его модели гистерезиса – это его фундаментальные свойства. Одним из эмпирических инструментов учета данных рынка является показатель Хёрста [4, 5]. К сожалению, глубокого теоретического обоснования корректного этого применения этого показателя для динамически нестационарных, нелинейно нестационарных систем с гистерезисом нет. Тем не менее шка-

ла корректно оцененного показателя Хёрста одновременно отображает и корреляционные связи между данными и нормированную их энтропию [11], как это отображено на рис. 5.




Рис. 5. Связь шкалы нормированной энтропии, корреляционной сцепленности и значений показателя Хёрста

Ранее было показано, корректная оценка показателя Хёрста на малых выборках может быть сделана, если при вычислениях устранять методические ошибки [12]. При этом оценки энтропии и показателя Хёрста по одной переменной (по одному тренду цен) обладают низкой предсказательной способностью. Снизить ошибки предсказаний возможно в случае нейросетевого обобщения данных для множества переменных [13]. Предположительно многомерный нейросетевой анализ рынка удастся выполнить многослойными сверточными сетями искусственных нейронов. При их обучении, видимо, придется использовать большие объемы достоверных данных того или иного сегмента рынка.

Библиографический список

1. Теория автоматического управления / под ред. А.В. Нетушила. М.: Высшая школа, 1976. 432 с.
2. Льюнг Л. Идентификация систем. Теория для пользователя. М.: Наука, 1991. 432 с.
3. Орлов Ю.Н., Осминин К.П. Нестационарные временные ряды. Методы прогнозирования с применением анализа финансовых и сырьевых рынков. М.: ЛЕНЛАНД, 2023. 384 с.
4. Найман Э. Как покупать дешево и продавать дорого: Пособие для разумного инвестора. М.: Альпина Паблицерз, 2011. 552 с.
5. Петерс. Э. Хаос и порядок на рынках капитала. Новый аналитический взгляд на циклы, цены и изменчивость рынка / пер. с англ. М.: МИР, 2000. 333 с.
6. Иванов А.И. Метод измерения параметров нелинейных объектов, ориентированный на применение в измерительно-вычислительных комплексах: автореферат диссертации на соискание ученой степени канд. техн. наук. Ленинград, 1983. 16 с.
7. Иванов А.И. Экономика промышленного искусственного интеллекта: получение сверхприбыли и сокращение рабочих мест // Системы безопасности. 2024. № 1. С. 140–143.
8. Иванов А.И., Тарасов Д.В., Горбунов К.А. Оценки показателя Херста на малых выборках: простейший вариант нелинейного компенсатора методических ошибок Федера при моделировании данных экономики и биометрии // Надежность и качество сложных систем. 2023. № 3. С. 50–54. doi: 10.21685/2307-4205-2023-3-6
9. Иванов А.И. Дерябин И.П., Князев В.А., Тырлов А.С., Лещев А.П. Имитационное моделирование симметричных циклов гистерезиса // Электричество. 1987. №8. С. 66–67.

10. Иванов А.И., Дерябин И.П., Князев В.А., Тырлов А.С., Лещев А.П. Устройство для моделирования гистерезиса // Авторское свидетельство на патент СССР № 1269157, БИ № 41, 1986.
11. Иванов А.И., Тарасов Д.В., Ермакова А.И. Программное воспроизведение корреляционных связей в малых выборках при статистическом анализе биометрических данных и данных рынка в пространстве значений эмпирического показателя Хёрста // Труды МАИ. 2024. № 137. URL: <https://trudymai.ru/published.php?ID=181892>
12. Иванов А.И., Тарасов Д.В. Дополнительная коррекция аддитивной методической погрешности оценок показателя Херста при анализе эмпирических данных // Проблемы информатики в образовании, управлении, экономике и технике :сб. ст. XXIII Междунар. науч.-техн. конф., посвящ. 80-летию Пензенского государственного университета (г. Пенза, 24–25 ноября 2023 г.) / под ред. А.В. Кузьмина, В.В. Дрождина. – Пенза : Изд-во ПГУ, 2023. С. 14–18.
13. Иванов А.И. Высокоразмерная коллективная биометрия подсознательного поведения людей на рынке и производстве : препринт. Пенза : Изд-во ПГУ, 2021. 60 с.

NEURAL NETWORK ANALYSIS OF A NONLINEAR DYNAMIC MARKET MODEL WITH HYSTERESIS BASED ON THE ALGORITHM FOR ESTIMATING HURST INDEX ON SMALL SAMPLES

Alexander I. Ivanov

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

Dmitry V. Tarasov

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

To describe the market, it is proposed to use the Hammerstein model with an input linear dynamic part and an output hysteresis nonlinearity. If we consider the input data of the Hammerstein model as chaos ("white noise"), then the sections of price decline and price rise correspond to different impulse transient functions of the linear dynamic part of the model. "White" and "colored" noise are characteristics of the entropy of the observed price change data. Entropy estimation on small samples is possible if entropy is estimated using convolutional neural networks, for example, based on neurons for evaluating the empirical Hurst indicator. The relationship of classical entropy with the empirical Hurst index and the correlation coupling index of the analyzed data is given.

Keywords: market model, hysteresis, dynamic model, market data partitioning, Hurst empirical indicator.

АЛГОРИТМЫ ДЛЯ ТРЕЙДИНГА

Шафар Иван Васильевич

Московский государственный технический университет гражданской авиации,
125493, Россия, г. Москва, Кронштадтский б-р, д. 20
i@ishafar.ru

В статье представлен аналитический обзор, посвященный применению автоматических систем и технологий машинного обучения в торговле на финансовых рынках. В условиях высоких рисков и турбулентной внешней среды, автоматизация процессов торговли позволяет трейдерам эффективно управлять рисками и извлекать прибыль на основе прогнозирования рыночных тенденций и выявления краткосрочных ценовых аномалий. Рассматриваются различные виды алгоритмов, используемых в алготрейдинге, такие как высокочастотная торговля, статистический арбитраж, алгоритмическая торговля на основе новостей, маркет-мейкинг и смарт-ордер раутинг. Также рассматривается перспектива замены трейдеров на бирже искусственным интеллектом, включая преимущества и вызовы, связанные с этим процессом. Особое внимание уделено роли машинного обучения в улучшении точности торговых стратегий и адаптации к изменяющимся рыночным условиям.

Ключевые слова: Алготрейдинг, алгоритмы, трейдинг, автоматизация, анализ данных.

Введение. В условиях быстроизменяющейся и турбулентной внешней среды торговля на финансовом рынке сулит получение прибыли, но так как данная торговля напрямую связана с рисками, то и вероятность провала высока. Современная практика применения автоматических систем принятия решения является неотъемлемой частью любого современного участника биржевых аукционов, позволяющая не только контролировать риски активных портфелей, но и извлекать моментную прибыль на основе прогнозирования тенденций в оценке стоимости торгуемых продуктов, а также краткосрочного неправильного ценообразования торгуемых инструментов [1].

Задача трейдера – не только совершение сделок, но и анализ всех внешних элементов, влияющих на тенденцию изменения цен акций на рынке, например, политические, экономические, технологические и др. Автоматизацию процессов следует изучать, начиная с применения инструментов, позволяющих формировать многофункциональную цифровую среду, к примеру Low-code платформы [3]. Также использование трейдером технологий обработки Big Data способствует более прозрачному и эффективному функционированию финансовых рынков.

Уменьшение человеческого вмешательства в процесс принятия решений снижает вероятность ошибок, связанных с эмоциональными факторами, и способствует формированию более стабильной и предсказуемой рыночной среды.

Для автоматизации повседневных операций, выполняемых трейдерами, существует понятие алготрейдинга. Алгоритмическая торговля как явление зародилась в 1998 г. в США. В 2000 году доля роботов на рынке США составляла

10%, а в 2009 году уже 60%. На данный момент около 30-50% торгов на Московской бирже генерируют торговые алгоритмы [2, 45].

Исследование предметной области. Использование алгоритмической торговли в настоящем, это уже не следование тренду, а неотъемлемая часть успешной стратегии на финансовых рынках. Рассмотрим различные типы алгоритмов, которые применяются в алготрейдинге:

- Алгоритмы высокочастотной торговли (High-Frequency Trading, HFT) – это разновидность алгоритмического трейдинга, которые выполняют ордера со скоростью менее 5 миллисекунд. Данную скорость обеспечивает использование сервисов колокаций, выделенного канала передачи данных или прямого доступа к рынку. Процесс принятия решения [4] автоматизирован с помощью использования специализированных компьютерных программ, с встроенным алгоритмом торговли. Распространённость данного вида торговли в настоящее время уменьшается так как из-за сложности реализации и необходимости в значительных оборотных средствах его использование становится прерогативой крупных банков, хедж-фондов и других крупных игроков. Так же не исключена возможность сбоя алгоритмов, как это произошло 6 мая 2010, что привело к падению на фондовом рынке.

- Статистический арбитраж (Statistical Arbitrage): это квантовая торговая стратегия, основанная на статистическом анализе и математических моделях для выявления и эксплуатации арбитражных возможностей на финансовых рынках. Стратегия часто включает в себя поиск пар активов, цены на которые исторически двигались вместе (например, акции двух компаний в одной отрасли), но в определённый момент начинают расходиться. Трейдеры, использующие статистический арбитраж, покупают актив, цена которого, по их мнению, недооценена, и одновременно продают коротко актив, который они считают переоцененным, ожидая, что цены вновь сойдутся.

Основные компоненты стратегии статистического арбитража:

1. Выбор пары активов: Используя исторические данные, трейдеры ищут пары активов с высокой степенью корреляции. Использование парного трейдинга начинается с определения на основе исторических данных пар активов, между ценами которых присутствует сильная статистическая взаимосвязь. Для подбора таких пар можно использовать фильтр Калмана, который является наилучшей доступной оценкой, минимизирующей среднеквадратичную ошибку прогноза оцениваемых переменных. [5, 79]

2. Моделирование: Применение статистических и математических моделей для оценки текущих цен активов по отношению к их историческим отношениям.

3. Исполнение: Автоматизированное исполнение ордеров на покупку и продажу на основе моделирования, с целью извлечения прибыли из временных ценовых аномалий. На рис. можно заметить, что эти два актива, привилегированные акции Сбербанка (SBERP) и акции сбербанка (SBER), ходят друг относительно друга. При этом между ними возникает спрэд (до 4%), а также их цены возвращаются к среднему значению.



Рис. Статистический арбитраж на российском фондовом рынке акции SBERP и SBER

- **Алгоритмическая торговля на основе новостей:** Эти алгоритмы анализируют новости и экономические отчеты в реальном времени, чтобы принимать торговые решения. Они могут реагировать на новости быстрее человека, автоматически исполняя ордера на покупку или продажу на основе содержания новостей. Данный алгоритм включает в себя несколько стратегий, таких как:

1. **Анализ настроений.** Суть заключается в машинном обучении на статьях и корреляции этих статей с поведением на бирже для дальнейшей экстраполяции и определения тенденций определенного актива.

2. **Торговля на основе событий.** В данной стратегии фокусируется внимание на таких новостях как слияние, поглощение, публикации отчетов об операционной деятельности.

- **Маркет-мейкинг:** Алгоритмы маркет-мейкинга создают рынок для актива, регулярно публикуя ордера на покупку и продажу с целью получения прибыли на спреде (разнице между ценой покупки и продажи). Маркет-мейкинг на фондовом рынке необходим, чтобы реализовать одно из допущений модели CAMP, а именно об отсутствии препятствий для совершения акта покупки и продажи. Наличие не спекулятивного маркет мейкинга необходимо для биржи. В настоящее время скорость публикации ордеров на столько велика, что осуществлять её вручную и конкурировать с автоматизированными методами невозможно.

- **Смарт-ордер раутинг (Smart OrderRouting, SOR):** Эти алгоритмы автоматически выбирают наилучшую площадку для исполнения ордера на основе цены, доступности и других факторов, улучшая шансы на лучшее исполнение ордера. Эта система стала ответом на законодательство США. В США рынок традиционно делился на четыре пласта, каждый из которых удовлетворял потребности различных целевых аудиторий, но брокеры направляли ордера на рынок, условия которого, были более выгодными для них, а не для инвестора. Брокер обязан иметь доказательство того, что он совершил сделку по лучшей цене, для этого каждый клиентский ордер имеет audittrail, этот «хвост» содержит информацию о цене и рынке исполнения ордера. SOR не только помогает брокеру следовать букве закона, но и, покупая по лучшей цене, более качественно обслуживать клиента, тем самым иметь преимущество в конкурентной борьбе среди других брокеров.

- Машинное обучение и искусственный интеллект (AI): Алгоритмы, использующие машинное обучение, могут включать в себя все вышеописанные методы и обучаться на исторических данных и самостоятельно адаптироваться к изменениям рынка для оптимизации торговых стратегий [6]. AI может использоваться для прогнозирования тенденций рынка, анализа больших объемов данных и принятия сложных торговых решений. Машинное обучение применяется в торговле для разработки моделей, способных анализировать Big Data и самостоятельно адаптироваться к новой информации, чтобы принимать более точные и взвешенные торговые решения. Это может включать прогнозирование направления рыночных трендов, определение оптимальных точек входа и выхода, а также управление рисками. Прогнозирование цен осуществляется на основе обучения модели на исторических данных, а также экстраполяции, т.е. аппроксимация направления тренда в будущем. Для трейдеров при торговле немаловажную роль играют паттерны, т.е. появление некой конкретной фигуры или индикатора (свечка), формируемого на графике ценной бумаги, которая в прошлом приводила к определённому результату, является сигналом для начала торговли. Модель машинного обучения может анализировать большой объём исторических данных и находить большее количество таких сигналов, чем человек. Скорость обработки данных позволяет вычислять ковариации случайных акций и рассматриваемых паттернов, тем самым можно математически определять влияние сторонних отраслей на поведение акций в портфеле. С помощью NLP модель, в режиме реального времени, будет рассматривать различные социальные и медиа новости, результатом такого анализа будет оценка настроений рынка и прогноз дальнейшего тренда.

Портфельные теории, а именно модели эффективных портфелей, разработаны и представлены уже давно, но они обладают рядом минусов. А именно большое количество допущений и расчётов. Модель, обученная на принципах, описанных выше, и имеющая вектор для составления эффективного портфеля, в виде модели CML, позволит минимизировать риск либо увеличить доходность портфеля.

Но есть и минус у машинного обучения. А именно явление, когда модель хорошо себя показывает на базе данных, на которых она обучалась, но на новых данных будет наблюдаться более низкая результативность. Это явление называется переобучение или переподгонка. В настоящее время для предотвращения чрезмерной подгонки существует множество методов, в основе которых лежит ограничение на сложность модели. Применение таких методов как перекрёстная проверка, регуляризация, априорная вероятность помогут предотвратить переобучение, но требуют дополнительных затрат и ограничивают возможности.

Важно понимать, что силами одних разработчиков невозможно построить высоко результативную модель. В процессе разработки модели должны принимать участие эксперты, обладающие глубоким пониманием рынков, на которых эта модель будет обучаться и использоваться.

Немаловажную роль играют внутренние договоренности и отсутствие инсайдерской информации у AI. Следует отметить, что выявляются риски использования вышеуказанных технологий:

1. Опасность технического сбоя, что характерно не только для искусственного интеллекта в трейдинге, а в целом для технологии. Что в длинных продажах и массовых коротких продажах принесет колоссальные убытки.

2. Создание мыльного пузыря, создание и использование действительно рабочего прототипа не станет секретом для фондовой биржи, а следовательно, количество пользователей многократно увеличится. Торговля таким методом не создаёт никакой ценности, а искусственно будет повышать или снижать спрос на ту или иную акцию.

Заключение. Таким образом искусственный интеллект показывает впечатляющие результаты в анализе данных и скорости принятия решений, также немаловажную роль играет отсутствие эмоций и круглосуточный режим работы искусственного интеллекта. Но при этом искусственный интеллект обладает рядом минусов и нерешённых вопросов. Отсутствие ответственного за действия искусственного интеллекта, непредсказуемость «Черных лебедей», ограниченность базы данных, на которой будет происходить обучение. Также несмотря на технологический прогресс, интуиция и человеческий опыт остаются, несомненно, важными факторами успешной торговли. Перспектива полной замены, конечно, выглядит многообещающей, но маловероятной в ближайшем времени.

Библиографический список

1. Ерешко, А. Ф. Проблемы алготрейдинга на финансовых рынках / А. Ф. Ерешко // Системный анализ и информационные технологии (САИТ – 2017) : Сборник трудов Седьмой Международной конференции, Светлогорск, 13–18 июня 2017 года. – Светлогорск: Федеральный исследовательский центр «Информатика и управление» Российской академии наук, 2017. – С. 533-536. – EDN ZGPRTR.

2. Трифонов, Н. О. Алготрейдинг: развитие, риски и применение / Н. О. Трифонов // ВЕКТОРЫ РАЗВИТИЯ современной науки : Сборник статей Международной научно-практической конференции, Петрозаводск, 29 декабря 2022 года. – г. Петрозаводск: Международный центр научного партнерства «Новая Наука» (ИП Ивановская И.И.), 2022. – С. 44-48. – EDN BEKQTW.

3. Степаненко, А. С. Low-code платформы как тенденция управления BPMS / А. С. Степаненко // Гражданская авиация на современном этапе развития науки, техники и общества : Сборник тезисов докладов Международной научно-технической конференции, посвященной 50-летию МГТУ ГА, Москва, 25–26 мая 2021 года. – Москва: ИД Академии Жуковского, 2021. – С. 475-476. – EDN AZTIPS.

4. Степаненко, Е. В. Современный менеджмент : тексты лекций / Е. В. Степаненко ; Е. В. Степаненко ; Федеральное агентство воздушного трансп., Федеральное гос. образовательное учреждение высш. проф. образования "Московский гос. технический ун-т гражданской авиации", Каф. менеджмента. – Москва : МГТУ ГА, 2009. – 84 с. – ISBN 978-5-86311-689-1. – EDN QTMJEJ.

5. Кириленко, Ю. П. Фильтр Калмана как алгоритм парного трейдинга на российском рынке / Ю. П. Кириленко // Математическое и компьютерное моделирование в экономике, страховании и управлении рисками. – 2022. – № 7. – С. 79-82. – EDN ZKBOPC.

6. Степаненко, А. С. Нейронные сети как инструмент прогнозирования в гражданской авиации / А. С. Степаненко, А. С. Щегольков // Актуальные проблемы и перспективы развития гражданской авиации : Сборник трудов XII Международной научно-практической конференции, посвященной празднованию 100-летия отечественной гражданской авиации, Иркутск, 12–13 октября 2023 года. – Иркутск: Московский государственный технический университет гражданской авиации, 2023. – С. 211-219. – EDN NAGDGT.

7. Погорелова, Е. В. Высокочастотный трейдинг с элементами искусственного интеллекта на фондовой бирже / Е. В. Погорелова, Д. С. Карташев // Проблемы развития предприятий: теория и практика. – 2019. – № 1-2. – С. 230-233. – EDN QOWXZR.

ALGORITHMS FOR TRADING

Ivan V. Shafar

Moscow State Technical University of Civil Aviation,
Blvd. Kronstadt, 20, Moscow, Russia, 125493
i@ishafar.ru

The article presents an analytical review on the application of automatic systems and machine learning technologies in trading in financial markets. In conditions of high risks and a turbulent external environment, automation of trading processes allows traders to effectively manage risks and make profits based on forecasting market trends and identifying short-term price anomalies. Various types of algorithms used in algotrading are considered, such as high-frequency trading, statistical arbitrage, algorithmic trading based on news, market making and smart order routing. The prospect of replacing traders on the stock exchange with artificial intelligence is also being considered, including the advantages and challenges associated with this process. Special attention is paid to the role of machine learning in improving the accuracy of trading strategies and adapting to changing market conditions.

Keywords: Algorithmic trading, algorithms, trading, automation, data analysis.

УДК 517.93; 519.83

ОПТИМИЗАЦИЯ ПРОГРАММНОГО УПРАВЛЕНИЯ ПРОГНОЗИРОВАНИЕМ СОСТОЯНИЯ ФАЗОВОГО ВЕКТОРА НЕЛИНЕЙНОЙ ДИСКРЕТНОЙ УПРАВЛЯЕМОЙ ДИНАМИЧЕСКОЙ СИСТЕМЫ

Шориков Андрей Федорович

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

В работе рассматривается нелинейная дискретная управляемая динамическая система при наличии фазового вектора объекта управления, управляющего воздействия субъекта управления и априори неопределенного возмущения. В каждый период времени фазовый вектор объекта и вектор возмущения стеснены многогранниками-компактами в соответствующих конечномерных векторных пространствах, а вектор управления принимает значения из конечного множества в соответствующем конечномерном векторном пространстве. Результат прогнозирования и оценивания состояния фазового вектора объекта управления в финальный период времени описывается целевой функцией, значения которой равны величине чебышевского радиуса соответствующих прогнозных множеств. Рассматривается нелинейная многошаговая задача оптимизации программного управления прогнозированием и минимаксным оцениванием состояния фазового вектора объекта управления в финальный период времени. Для ее решения предлагается методика, которая осуществляется путем реализации конечной последовательности только одношаговых операций, допускающих их алгоритмизацию. Полученные результаты могут быть использованы для разработки компьютерных интеллектуальных информационных систем оптимизации управления сложными техническими объектами и социально-экономическими системами.

Ключевые слова: нелинейная дискретная динамическая модель, прогнозирование данных, минимаксные оценки прогнозного множества, оптимизация программного управления.

Введение. В статье рассматривается объект управления, динамика которого описывается нелинейной дискретной управляемой динамической системой при наличии фазового вектора объекта управления, управляющего воздействия субъекта управления и априори неопределенного возмущения. В каждый период времени фазовый вектор объекта и вектор возмущения стеснены многогранниками-компактами в соответствующих конечномерных векторных пространствах, а вектор управления принимает значения из конечного множества в соответствующем конечномерном векторном пространстве. Результат прогнозирования и минимаксного оценивания состояния фазового вектора объекта управления в финальный период времени описывается целевой функцией, значения которой равны величине чебышевского радиуса соответствующих прогнозных множеств. Рассматривается задача оптимизации программного управления прогнозированием и минимаксным оцениванием состояния фазового вектора объекта управления в финальный период времени. Для ее формализации и решения используется детерминированный подход оптимизации гарантированного результата [1-4] и предлагается методика, основывающаяся на *общем рекуррентном алгебраическом методе* (Шорилов А.Ф., [4]) построения областей достижимости (прогнозных множеств) линейных дискретных управляемых динамических систем и использовании *метода редукции к задаче выпуклого математического программирования* (Шорилов А.Ф., [4]) для вычисления минимаксных оценок многогранника-компакта в конечномерном векторном пространстве. Полученные в статье результаты примыкают к работам [1-3], основываются на результатах работ [4-6] и могут быть использованы для разработки компьютерных интеллектуальных информационных систем оптимизации управления сложными техническими объектами и социально-экономическими системами.

Математическая модель динамики процесса управления прогнозированием и оцениванием данных. Ниже опишем математическую модель динамики, соответствующую исследуемой оптимизационной задаче прогнозирования и оценивания фазовых состояний объекта управления.

Пусть на заданном целочисленном промежутке времени (далее просто – промежутке времени) $\overline{0, T} = \{0, 1, \dots, T\}$ ($T \in \mathbf{N}$; здесь и далее, $\mathbf{N}$ – множество всех натуральных чисел) динамика объекта управления – объекта I, описывается его моделью – нелинейным дискретным рекуррентным уравнением вида

$$x(t+1) = f(t, x(t), u(t), v(t)), \quad x(0) = x_0, \quad t \in \overline{0, T-1}, \quad (1)$$

где $x(t) = (x_1(t), x_2(t), \dots, x_n(t))'$ – фазовый вектор модели объекта I в период времени t , $x(t) \in \mathbf{R}^n$ ($n \in \mathbf{N}$) (здесь и далее, для $k \in \mathbf{N}$, $\mathbf{R}^k$ – k -мерное векторное пространство векторов-столбцов, даже если из экономии места они записаны в

строку; x_0 – заданное начальное значение фазового вектора); $u(t) = (u_1(t), u_2(t), \dots, u_p(t))'$ – вектор управляющего воздействия (управления) субъекта управления – агента P , $u(t) \in \mathbf{R}^p$ ($p \in \mathbf{N}$); $v(t) = (v_1(t), v_2(t), \dots, v_q(t))'$ – вектор априори неопределенного возмущения (помехи, погрешности моделирования) в период времени t , $v(t) \in \mathbf{R}^q$ ($q \in \mathbf{N}$).

Ниже полагается, что для фиксированного $\delta \in \mathbf{N}$ и соответствующего конечномерного векторного пространства $\mathbf{R}^\delta$ символом $\Sigma(\mathbf{R}^\delta)$ обозначается множество всех конечных подмножеств этого пространства, а символом $\Xi(\mathbf{R}^\delta)$ – множество всех выпуклых многогранников-компактов (с конечным числом вершин), содержащихся в этом пространстве, включающее, например, множество всех параллелепипедов (по определению полагается, что одноэлементные множества в рассматриваемых конечномерных векторных пространствах являются выпуклыми многогранниками-компактами).

Предполагается, что параметры рекуррентного уравнения (1) должны удовлетворять следующим заданным ограничениям:

$$\forall t \in \overline{0, T} : x(t) \in X^*(t) \in \Xi(\mathbf{R}^n); \quad (2)$$

$$\forall t \in \overline{0, T-1} : u(t) \in U^*(t) = \{u^{(1)}(t), u^{(2)}(t), \dots, u^{(K_t)}(t)\} \in \Sigma(\mathbf{R}^p) (K_t \in \mathbf{N}); \quad (3)$$

$$(\forall t \in \overline{0, T-1}) \wedge (u(t) \in U^*(t)) : v(t) \in V_*(t; u(t)) \in \Xi(\mathbf{R}^q). \quad (4)$$

Отметим, что в (2) и (4), для $\forall t \in \overline{0, T}$ множества $X^*(t)$ и $\forall t \in \overline{0, T-1}, \forall u(t) \in U^*(t)$ множества $V^*(t; u(t))$ могут быть заданы, например, в виде соответствующих многомерных параллелепипедов в пространствах $\mathbf{R}^n$ и $\mathbf{R}^q$ соответственно.

Предполагается также, что функция $f : \overline{0, T-1} \times \mathbf{R}^n \times \mathbf{R}^p \times \mathbf{R}^q \rightarrow \mathbf{R}^n$, определяющая правую часть рекуррентного уравнения (1), $\forall t \in \overline{0, T-1}$ непрерывна по совокупности переменных $\{x(t), u(t), v(t)\}$ и для каждого набора $\{t, X(t), u(t)\} \in \overline{0, T-1} \times \Xi(\mathbf{R}^n) \times U^*(t)$ множество $f(t, X(t), u(t), V_*(t; u(t))) = \{f(t, x(t), u(t), v(t)), x(t) \in X(t), v(t) \in V_*(t; u(t))\}$ есть выпуклый компакт пространства $\mathbf{R}^q$.

Предполагается, что на рассматриваемом промежутке времени $\overline{0, T}$ в любой период времени $\tau \in \overline{0, T}$ в процессе программного управления прогнозированием и оцениванием фазовых состояний объекта I агентом P измеряется и запоминается вектор $x(\tau) = x_\tau$ – фазовый вектор модели объекта I , описываемой рекуррентным уравнением (1), в период времени τ ($x(0) = x_0$). Предполагается также, что рекуррентное уравнение (1), описывающее динамику модели объекта I , и ограничения (2) – (4), для него также известны.

Постановка задачи оптимизации управления прогнозированием и оцениванием фазовых состояний объекта I . Введем ряд определений, которые необходимы для математической формализации задачи оптимизации

управления прогнозированием и минимаксным оцениванием фазовых состояний объекта рассматриваемой динамической системы (1) – (4) в финальный период времени T .

Здесь и далее, для $k \in \mathbf{N}$ и целочисленного промежутка времени $\overline{\tau, \vartheta} \subseteq \overline{0, T}$ ($\tau < \vartheta$), символом $\Omega_k(\overline{\tau, \vartheta})$ будем обозначать метрическое пространство вектор-функций целочисленного аргумента (далее, просто – функций) $\omega: \overline{\tau, \vartheta} \rightarrow \mathbf{R}^k$, в котором метрика ρ_k задается соотношением

$$\rho_k(\omega_1(\cdot), \omega_2(\cdot)) = \max_{t \in \overline{\tau, \vartheta}} \|\omega_1(t) - \omega_2(t)\|_k, \{\omega_1(\cdot), \omega_2(\cdot)\} \in \Omega_k(\overline{\tau, \vartheta}) \times \Omega_k(\overline{\tau, \vartheta}),$$

а символом $\text{comp } \Omega_k(\overline{\tau, \vartheta})$ – множество всех непустых и компактных, в смысле этой метрики, подмножеств пространства $\Omega_k(\overline{\tau, \vartheta})$ (здесь и далее, символом $\|\cdot\|_k$ обозначается евклидова норма для элементов пространства $\mathbf{R}^k$).

Используя ограничение (3), определим множество $\mathbf{U}(\overline{\tau, T}) \in \Omega_p(\overline{\tau, T-1})$ ($\tau < T$) допустимых на промежутке времени $\overline{\tau, T}$ программных управлений агента P соотношением

$$\mathbf{U}(\overline{\tau, T}) = \{u_\tau(\cdot) : u_\tau(\cdot) = \{u_\tau(t)\}_{t \in \overline{\tau, T-1}} \in \Omega_p(\overline{\tau, T-1}), \forall t \in \overline{\tau, T-1}, u_\tau(t) \in \mathbf{U}^*(t)\} \quad (5)$$

и $\forall u_\tau(\cdot) \in \mathbf{U}(\overline{\tau, T})$, используя ограничение (4), определим множество $\mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)) \in \text{comp } \Omega_q(\overline{\tau, T-1})$ допустимых на промежутке времени $\overline{\tau, T}$ программных возмущений соотношением

$$\mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)) = \{v_\tau(\cdot) : v_\tau(\cdot) = \{v_\tau(t)\}_{t \in \overline{\tau, T-1}} \in \Omega_q(\overline{\tau, T-1}), \forall t \in \overline{\tau, T-1}, v_\tau(t) \in \mathbf{V}^*(t)\}. \quad (6)$$

Назовем набор $w(\tau) = \{\tau, x(\tau)\} \in \overline{0, T} \times \mathbf{R}^n$ ($w(0) = \{0, x(0)\} = \{0, x_0\} = w_0$) τ -позицией дискретной управляемой динамической системы (1) – (4), или просто – τ -позицией системы, и определим множество $\mathbf{W}(\tau) = \{\tau\} \times \mathbf{X}^*(t)$ ($\mathbf{W}(0) = \{0\} \times \mathbf{X}^*(0) = \mathbf{W}_0$) всех допустимых τ -позиций рассматриваемой системы.

Пусть $\bar{x}_\tau(\cdot) = \psi_{\overline{\tau, T}}(\cdot; x_\tau, u_\tau(\cdot), v_\tau(\cdot)) = \{\bar{x}_\tau(t)\}_{t \in \overline{0, T}}$ – допустимая на промежутке времени $\overline{\tau, T}$ фазовая траектория объекта I , соответствующая допустимому набору $\{w_\tau, u_\tau(\cdot), v_\tau(\cdot)\} \in \mathbf{W}(\tau) \times \mathbf{U}(\overline{\tau, T}) \times \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot))$ ($w(\tau) = \{\tau, x_\tau\} = w_\tau$, $w(0) = \{0, x_0\} = w_0$), если $\forall t \in \overline{\tau, T} : \bar{x}_\tau(t) = \psi_{\overline{\tau, T}}(t; x_\tau, u_\tau(\cdot), v_\tau(\cdot)) \in \mathbf{X}^*(t)$, $\bar{x}_\tau(\tau) = x_\tau$, где $\psi_{\overline{\tau, T}} : \mathbf{R}^n \times \Omega_p(\overline{\tau, T-1}) \times \Omega_q(\overline{\tau, T-1}) \rightarrow \Omega_n(\overline{\tau, T})$ – оператор правой части уравнения (1), действующий на промежутке времени $\overline{\tau, T}$.

Обозначим символом $\mathbf{X}(\cdot; \overline{\tau, T}, X, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))$ – трубку всех допустимых на промежутке времени $\overline{\tau, T}$ фазовых траекторий $\bar{x}_\tau(\cdot) = \psi_{\overline{\tau, T}}(\cdot; x_\tau, u_\tau(\cdot), v_\tau(\cdot))$, $x_\tau \in X$, $v_\tau(\cdot) \in \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot))$, объекта I [4], соответствующую набору $\{X, u_\tau(\cdot)\} \in 2^{\mathbf{R}^n} \times \mathbf{U}(\overline{\tau, T})$, а через

$\mathbf{X}(t; \overline{\tau, T}, X, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))$ обозначим ее сечение в период времени $t \in \overline{\tau+1, T}$, которое назовем *обобщенной областью достижимости* [4] или *прогноznым множеством объекта I* дискретной управляемой динамической системы (1) – (4) в период времени t . Можно показать, аналогично результатам из [4], что для рассматриваемой динамической системы это множество является выпуклым компактом пространства $\mathbf{R}^n$, если X – выпуклый компакт в $\mathbf{R}^n$.

Будем предполагать, что для рассматриваемой динамической системы (1) – (4) выполняется следующее условие:

$$\exists \tilde{u}_\tau(\cdot) \in \mathbf{U}(\overline{\tau, T}): \mathbf{X}(t; \overline{\tau, T}, X, \tilde{u}_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot))) \neq \emptyset. \quad (7)$$

Пусть $\mathbf{r}_T^{(e)} = \mathbf{r}(\mathbf{X}(T; \overline{\tau, T}, \{x_\tau\}, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot))))$ – значение величины *чеbышевского радиуса прогнозного множества* $\mathbf{X}(T; \overline{\tau, T}, \{x_\tau\}, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))$, а $x_T^{(e)} \in \mathbf{X}(T; \overline{\tau, T}, \{x_\tau\}, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))$ – его *чеbышевский центр* (см., например, [4]). Тогда определим целевую функцию $\Phi_{\tau, T}: \mathbf{W}(\tau) \times \mathbf{U}(\overline{\tau, T}) \rightarrow \mathbf{R}^1$, значения которой для каждого набора $\{w_\tau, u_\tau(\cdot)\} \in \mathbf{W}(\tau) \times \mathbf{U}(\overline{\tau, T})$ определяются по формуле

$$\Phi_{\tau, T}(w_\tau, u_\tau(\cdot)) = \mathbf{r}(\mathbf{X}(T; \overline{\tau, T}, \{x_\tau\}, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))) = \mathbf{r}_T^{(e)}. \quad (8)$$

Тогда на основании сформированной модели (1) – (8) сформулируем следующую *нелинейную многошаговую задачу оптимизации программного управления прогнозированием и минимаксным оцениванием фазовых состояний объекта I* дискретной управляемой динамической системы (1) – (4) в финальный период времени T .

Задача. Для заданных целочисленного промежутка времени $\overline{0, T}$, периода времени τ ($\tau \in \overline{0, T-1}$), τ -позиции

$$w(\tau) = \{\tau, x(\tau)\} = \{\tau, x_\tau\} = w_\tau \in \mathbf{W}(\tau) \quad (w(0) = \{0, x(0)\} = \{0, x_0\} = w_0 \in \mathbf{W}_0)$$

дискретной управляемой динамической системы (1) – (4), целевой функции $\Phi_{\tau, T}$ вида (8), допустимого программного управления $u_\tau(\cdot) \in \mathbf{U}(\overline{\tau, T})$ и числа $\varepsilon > 0$ требуется сформировать множество $\mathbf{X}^{(\varepsilon)}(T; \overline{\tau, T}, \{x_\tau\}, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))$, которое с точностью до ε (в хаусдорфовой метрике для пространства $\mathbf{R}^n$) аппроксимирует прогнозное множество $\mathbf{X}(T; \overline{\tau, T}, \{x_\tau\}, u_\tau(\cdot), \mathbf{V}(\overline{\tau, T}; u_\tau(\cdot)))$ и найти конечное множество ε -оптимальных программных управлений

$$\mathbf{U}_{\Phi_{\tau, T}}^{(\varepsilon)}(\overline{\tau, T}; w_\tau) = \{u_\tau^{(\varepsilon)}(\cdot)\} \subseteq \mathbf{U}(\overline{\tau, T})$$

агента P , минимизирующих (с точностью до ε) значения целевой функции $\Phi_{\tau, T}$, путем реализации конечного числа одношаговых операций, допускающих их алгоритмизацию.

Можно показать, что при сделанных предположениях и введенных ограничениях на параметры модели (1) – (8), решение сформулированной нелинейной многошаговой задачи существует.

Заключение. Для решения сформулированной задачи предлагается методика, которая для формирования множества $X^{(\varepsilon)}(T; \overline{\tau}, T, \{x_\tau\}, u_\tau(\cdot), V(\overline{\tau}, T; u_\tau(\cdot)))$ – ε -аппроксимации прогнозного множества $X(T; \overline{\tau}, T, \{x_\tau\}, u_\tau(\cdot), V(\overline{\tau}, T; u_\tau(\cdot)))$ финальных фазовых состояний объекта I рассматриваемой динамической системы (1) – (4) использует *общий рекуррентный алгебраический метод построения областей достижимости* (Шориков А.Ф. [4]) линейных дискретных управляемых динамических систем, для нахождения минимаксных оценок этого множества использует *метод редукции к задаче выпуклого математического программирования* (Шориков А.Ф. [4]) и сводится к реализации конечной последовательности решений только одношаговых задач, допускающих их алгоритмизацию.

В данной работе исследуется нелинейная многошаговая задача оптимизации программного управления прогнозированием и минимаксным оцениванием состояния фазового вектора объекта управления в финальный период времени. Для ее решения предлагается методика, которая осуществляется путем реализации конечной последовательности только одношаговых операций, допускающих их алгоритмизации. Полученные результаты могут быть использованы для разработки компьютерных интеллектуальных информационных систем оптимизации управления сложными техническими объектами и социально-экономическими системами.

Работа выполнена в соответствии с Планом НИР Института экономики УрО РАН.

Библиографический список

1. Красовский Н.Н. Теория управления движением. – М.: Наука, 1968.
2. Красовский Н.Н., Субботин А.И. Позиционные дифференциальные игры. – М.: Наука, 1974.
3. Куржанский А.Б. Управление и наблюдение в условиях неопределенности. – М.: Наука, 1977.
4. Шориков А.Ф. Минимаксное оценивание и управление в дискретных динамических системах. Екатеринбург: Изд-во Урал. гос. ун-та, 1997.
5. Шориков А.Ф. Оптимизация программного управления прогнозированием состояния фазового вектора линейной дискретной управляемой динамической системы // Математика, ее приложения и математическое образование (МПМО'23): Материалы VIII Междунар. конф. Улан-Удэ: Изд-во ВСГУТУ, 2023. С. 255–258.
6. Тюлюкин В.А., Шориков А.Ф. Об одном алгоритме построения области достижимости линейной управляемой системы // Негладкие задачи оптимизации и управление. Свердловск. УроАН СССР. 1988. С. 55-61.

OPTIMIZATION OF PROGRAM CONTROL FOR PREDICTION OF THE STATE OF THE PHASE VECTOR OF A NONLINEAR DISCRETE-TIME CONTROLLED DYNAMICAL SYSTEM

ShorikovAndrey F.

Institute of Economics of the Ural Branch of the RAS,
Str. Moskovskaya, 29, Ekaterinburg, Russia, 620014
afshorikov@mail.ru

The paper considers a nonlinear discrete-time controlled dynamical system in the presence of a phase vector of a control object, a control action of a control subject, and an a priori uncertain disturbance. In each period of time, the phase vector of the object and the disturbance vector are constrained by compact polyhedrons in the corresponding finite-dimensional vector spaces, and the control vector takes values from a finite set in the corresponding finite-dimensional vector space. The result of prediction and estimating the state of the phase vector of the control object in the final period of time is described by the objective function whose values are equal to the Chebyshev radius of the corresponding prediction sets. A nonlinear multi-step problem of optimization of program control of prediction and minimax estimation of the state of the phase vector of the control object in the final period of time is considered. To solve it, a technique is proposed that is implemented by implementing a finite sequence of only one-step operations that allow their algorithmization. The results obtained can be used to develop computer intelligent information systems for optimizing the control of complex technical objects and socio-economic systems.

Keywords: nonlinear discrete-time dynamical model, data prediction, minimax estimates of the prediction set, optimization of program control.

Секция: Искусственный интеллект, техника и промышленные технологии

УДК 004.032.26

ОПЫТ СОЗДАНИЯ И ВНЕДРЕНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ НА ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЯХ

*Миролюбова Татьяна Васильевна¹, Рыбакин Владимир Ильич²,
Голдобин Максим Алексеевич³, Морозов Андрей Александрович³,
Мезенцев Алексей Сергеевич¹, Ясницкий Виталий Леонидович⁴,
Ясницкий Леонид Нахимович^{1,5}*

¹Пермский государственный национальный исследовательский университет,
614068, Россия, г. Пермь, ул. Букирева, 15

²ООО Софт Менеджмент, Россия, г. Пермь, ул. Промышленная, 48.

³АО «ОДК-Пермские моторы»,
614010, Россия, г. Пермь, Комсомольский проспект, 93
goldmaxprof@rambler.ru

⁴Пермский национальный исследовательский политехнический университет,
614068, г. Пермь, Комсомольский проспект, д. 29

⁵Национальный исследовательский университет
«Высшая школа экономики»,
614070, Россия, г. Пермь, ул. Студенческая, 38
yasn@psu.ru

Приведены результаты разработки и применения систем искусственного интеллекта на серийных производственных предприятиях. Показаны положительные эффекты от их внедрения.

Ключевые слова: лопатка газотурбинного двигателя, качество, брак, компьютерный эксперимент, химический состав, сырьевой материал.

Введение. В настоящее время не вызывает сомнений, что разработка и внедрение методов искусственного интеллекта в производственную деятельность промышленных предприятий имеет большие перспективы. Однако этот процесс осложняется как объективными, так и субъективными причинами.

К субъективным причинам мы относим слабое понимание руководителями предприятий и инженерно-техническими работниками всех возможностей искусственного интеллекта, а также бюрократические сложности, связанные с проблемами финансового обеспечения проектов. Объективными причинами являются трудности сбора статистической информации и ее низкое качество.

Ниже приводится опыт и результаты многолетней НИР в области разработки и внедрения систем искусственного интеллекта на некоторых предприятиях, выпускающих серийную промышленную продукцию.

1. Интеллектуальная система управления качеством литья охлаждаемых лопаток газотурбинных двигателей. Качество литья охлаждаемых лопаток газотурбинных двигателей зависит от точности и качества изготовления керамических стержней, формирующих внутренние полости отливок лопаток в процессе их получения. Качество литейных стержней, в свою очередь, определяется сочетанием большого количества технологических параметров. Нами было выделено около 40 таких параметров, которые, по мнению специалистов, оказывают наибольшее влияние на качество результатов прессования керамических стержней.

На заводе удалось собрать около 400 примеров прессования литейных стержней. Каждый из примеров содержал комплекс параметров, характеризующих процесс получения заготовки (входные параметры), и результат контроля (выходные параметры).

Хотя статистическая выборка для обучения нейронной сети была крайне мала, зашумлена статистическими выбросами и сильно перекошена, применение методических приемов Пермской научной школы искусственного интеллекта [1, 2] позволило спроектировать приемлемую для практического применения нейронную сеть слоистой структуры прямого распространения с сигмоидными активационными функциями. Погрешность классификации, выполненная нейросетью на тестовом множестве примеров, составила 5%, а это значит, что, не смотря на ограниченность и дисбаланс выборки, нейронная сеть правильно усвоила закономерности моделируемой предметной области, адекватна ей и пригодна для ее исследования методом проведения виртуальных компьютерных экспериментов. Результаты этих экспериментов позволили:

- определить значимость технологических параметров, влияющих на образование дефектов;
- определить оптимальный набор технологических параметров, обеспечивающих снижение брака и улучшение качества изделий;
- разработать регламент на допустимые отклонения технологических параметров, обеспечивающих минимум брака и максимально высокое качество изделий.

Снабжение обученных нейронных сетей пользовательским интерфейсом позволило разработать системы искусственного интеллекта Dfektpredictor 2.0 [3] и Deviationpredictor 1.0 [4], которые в настоящее время используются на заводе при настройке технологических параметров производства изделий ответственного назначения. Согласно акту внедрения, использование разработанных интеллектуальных систем позволило сократить брак и издержки производства изделий. Кроме того, данные интеллектуальные системы позволяют вырабатывать у специалистов более глубокое понимание взаимосвязей, существующих между технологическими параметрами изготовления литейных стержней и вероятностью возникновения брака.

2. Интеллектуальная система управления качеством литья крупнотоннажных деталей железнодорожных вагонов. На продукции металлургического предприятия, серийно выплавляющего стальные отливки мартеновским способом весом 0,5 тонн, неожиданно стали возникать дефекты в виде трещин.

Причем, средний процент брака достигал 24,6%. Попытки определить причины образования трещин продолжались два месяца и результатов не дали. За эти два месяца были собраны статистические данные по 120 плавкам. Каждое наблюдение, соответствующее одной плавке, содержало 12 параметров, характеризующих химический состав металла и один параметр, фиксирующий процент брака каждой плавки.

С помощью наших программных инструментов была спроектирована специальная нейронная сеть, в результате применения которой были выявлены закономерности плавильного процесса и с помощью этих закономерностей были разработаны рекомендации по корректировке химического состава сырьевого материала.

Использование наших рекомендаций на заводе позволило снизить процент брака производимых отливок в 2,9 раз.

3. Интеллектуальная система для оптимизации технологического процесса производства кабельной продукции. При производстве кабельно-проводниковой продукции технологу приходится решать сложную задачу оптимального подбора параметров технологического процесса волочения-скрутки токопроводящих жил, обеспечивающего потребительские качества производимого кабеля при минимальных производственных затратах. Задача создания нейросетевой интеллектуальной системы, предназначенной для оптимизации этого процесса, осложнялась тем, что на заводе имелось всего девять результатов замеров параметров технологического процесса.

Однако, не смотря на существенно малый объем статистической информации, использование инструментов Пермской научной школы искусственного интеллекта, нам удалось спроектировать и создать нейронную сеть, средне-квадратичная относительная ошибка которой при тестовых испытаниях не превысила 10%. Это позволило методом замораживания входных параметров [1] выполнить серию виртуальных компьютерных экспериментов, выявить закономерности технологического процесса и найти оптимальный режим волочения-скрутки, при котором достигается минимальная погонная масса токопроводящей жилы. В частности, было найдено оптимальное сочетание диаметра проволоки и шага скрутки.

При использовании на заводе рекомендованных нейросетевой системой технологических параметров была зафиксирована экономия алюминия 1,3%.

Заключение. Применение методов искусственного интеллекта на ряде серийных производственных предприятий позволило подобрать оптимальные параметры технологических процессов, сократить процент брака, повысить качество производимой продукции, разработать регламент на химический состав сырьевой массы и технологические параметры, обеспечивающий максимальное качество производимой продукции при минимальном проценте брака и издержках производства.

Поддержка исследования. Исследование выполнено при финансовой 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. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
<https://cloud.mail.ru/public/5H3z/4LxCpisxw>
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. 9(2). Pp. 1814-1816.
https://www.academia.edu/43007435/Algorithm_for_Searching_and_Analyzing_Abnormal_Observations_of_Statistical_Information_Based_on_The_Arnold_Kolmogorov_Hecht-Nielsen_Theorem
3. Ясницкий Л.Н., Черепанов Ф.М., Мезенцев А.С., Ясницкий В.Л., Морозов А.А., Голдобин М.А. Система искусственного интеллекта «Defectpredictor 2.0» в виде настольного приложения. Свидетельство о регистрации программы для ЭВМ 2023666283, 28.07.2023. Заявка № 2023617673 от 24.04.2023 Samoilovich, Yu.A., Yasnitskii, L.N. Coupled problem of heat transfer, hydrodynamics, and solidification in a melt. Journal of Engineering Physics. 1981. 41(6), pp. 1377-1384.
<https://link.springer.com/article/10.1007/BF00825176>
4. Ясницкий Л.Н., Черепанов Ф.М., Мезенцев А.С., Ясницкий В.Л., Морозов А.А., Голдобин М.А. Система искусственного интеллекта «Deviationpredictor 1.0» в виде настольного приложения. Свидетельство о регистрации программы для ЭВМ 2023666214, 26.07.2023. Заявка № 2023617676 от 24.04.2023

EXPERIENCE OF CREATION AND IMPLEMENTATION OF INTELLIGENT SYSTEMS AT INDUSTRIAL ENTERPRISES

***Tatyana Mirolyubova¹, Vladimir Rybakin²,
Maxim A. Goldobin³, Andrey A. Morozov³,
Aleksey S. Mezentsev¹, Vitaly L. Yasnitsky⁴,
Leonid N. Yasnitsky^{1,5}***

¹Perm State National Research University,
15, Bukireva str., Perm, Russia, 614068

²Soft Management LLC, 48, Promyshlennaya str., Perm, Russia.

³JSC ‘ODK-Perm Motors’,
93, Komsomolsky Prospekt, Perm, 614010, Russia.
goldmaxprof@rambler.ru

⁴Perm National Research Polytechnic University,
614068, Perm, Komsomolsky Prospekt, 29, Komsomolsky Ave. 29

⁵National Research University
‘Higher School of Economics’,
614070, Russia, Perm, 38, Studencheskaya str.
yasn@psu.ru

The results of development and application of artificial intelligence systems at serial production enterprises are presented. Positive effects from their introduction are shown.

Key words: gas turbine engine blade, quality, defect, computer experiment, chemical composition, raw material.

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ И ВЫЯВЛЕНИЯ ПРИЧИН БРАКА ПРИ ПРЕССОВАНИИ ЛИТЕЙНЫХ СТЕРЖНЕЙ

Светлов Владимир Николаевич

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

В статье представлено описание разработки нейросетевой системы для прогнозирования результатов и выявления причин брака в промышленном производстве литейных стержней. Система позволяет с высокой точностью выявить наиболее значимые параметры технологического процесса, применяемого при прессовании литейных стержней, влияющие на производство некачественной продукции.

Ключевые слова: сырьевой материал, взаимозависимые переменные, искусственный интеллект, нейросетевые технологии, прогнозирование, промышленное производство, литейный стержень.

Введение. В настоящее время одной из важнейших задач авиадвигателестроения является повышение надежности газотурбинных двигателей (ГТД). Прежде всего, это касается технологий изготовления ответственных деталей горячего тракта, таких как лопатки турбины, так как они максимально нагружены и определяют ресурс работы двигателя. Лопатки характеризуются сложной пространственной формой, высокими требованиями к точности геометрических параметров.

В зависимости от условий работы лопаток меняется их конструкция и предъявляемые к ним требования. При изготовлении охлаждаемых лопаток, потребуется изготавливать литейные керамические стержни, которые оформляют внутренние полости отливки. Требования к стержню весьма жесткие: химическая инертность к сплаву, достаточная прочность при высоких температурах, геометрическая стабильность при нагреве, стабильность усадки при обжиге и т.д. [5].

В настоящее время к качеству таких изделий массового производства предъявляются повышенные требования. При больших объемах партий изделий возникает проблема, заключающаяся в необходимости своевременного получения объективной информации о состоянии технологического процесса для оперативного управления. Для предупреждения выпуска бракованных изделий требуется использование передовых методов прогнозирования их качества. К таким методам в настоящее время относится метод математического моделирования на основе решения краевых задач [7] и метод искусственных нейронных сетей (ИНС) [1, 2].

Метод искусственных нейронных сетей позволяет моделировать сложный тех. процесс с нелинейными связями между параметрами при большом числе взаимозависимых переменных.

Данная проблематика изложена в статье [4]. Разработанная ее авторами методика управления качеством изделий массового производства: подготовка данных, построение и обучение ИНС, была осуществлена в пакете программ STATISTICANeuralNetworks (нейро-сетевой пакет фирмы StatSoft).

Основная цель настоящей работы заключается, в представленном множестве технологических параметров, производства лопаток турбин ГТД, произвести выборку тех.процесса по изготовлению стержней, которые оформляют внутренние полости отливки. Из выбранного множества произвести отсеивание статических параметров, а также выявить и удалить некорректные данные. Конечным результатом должна быть нейросетевая система, способная прогнозировать параметры технологического процесса, влияющие на причины производства бракованной продукции в больше чем 70% случаев.

Для создания нейросетевой системы были выбраны 20 параметров технологического процесса серийного производства литейных стержней. Данные параметры были обозначены как X1 – X20. Выходной параметр – процент брака производства.

Перед переходом к проектированию и обучению нейросетевой модели, была выполнена очистка исходного множества от противоречивых примеров, выбросов, дубликатов. Например, некорректными примерами считались те, где отсутствовали ряд данных в линейке. Изначально были представлены 538 примера для исследования, где только 35 имели примеры с браком. Для достижения хороших результатов представленное множество было подвергнуто аугментации данных, чтобы улучшить результаты модели. Перед выполнением аугментации из представленного множества были выделены тестовых примера, которые в свою очередь аугментации не подвергались, в процессе обучения нейросети не использовались.

Таким образом, объем итогового множества включает в себя 958 примеров. Из данного множества было сформировано обучающее (649), валидирующее (209) и тестирующее (100) в соотношении 68%, 22% и 10 % соответственно.

Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [6] по методике [1]. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет двадцать входных нейронов, один выходной и один скрытый слой с десятью нейроном.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 100 примеров. Средняя относительная ошибка тестирования составила 20,08 %, что можно считать приемлемым результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью выпуском бракованной продукцией. Из результатов, изображенных на рис. 1, можно сделать вывод об адекватной работе спроектированной нейронной сети – коэффициент детерминации составил 68,4 %.




Рис. 1. Результат тестирования нейронной сети

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5», результат отображен на рис. 2. Как видно из рис. 2, наиболее значимыми являются параметры X12, X-11, X-14, (различные температурные режимы, используемые в технологическом процессе).

Далее было проведено исследование полученных зависимостей между входными параметрами и процентом брака. Исследование производилось с помощью метода «замораживания», суть которого заключается в варьировании значения одного параметра и фиксировании значений всех других параметров. Для этой цели был отобран «нейтральный пример», про который нейросеть не может с уверенностью сказать, что при введенных параметрах технологического процесса, получится: брак или годный продукт.




Рис. 2. Значимость входных параметров нейросетевой модели

На рис. 3 показан график зависимости прогнозируемого процента брака от параметра X12. В том случае, когда происходит увеличение температуры, нейросеть прогнозирует значительное увеличение шанса на получение бракованного изделия.




Рис. 3. Зависимость прогнозируемого процента брака от параметра X12

На рис. 4 продемонстрирована зависимость прогнозируемого процента брака от параметра X14. В данном случае наблюдается обратный эффект: при снижении температуры в определённом диапазоне вероятность получения бракованного изделия снижается.




Рис. 4. Зависимость прогнозируемого процента брака от параметра X14

На рис. 5 изображен график зависимости вероятности получения брака от показателя параметра X11. Как видно из графика, при температуре нейросеть прогнозирует значительное увеличение шанса на получение бракованного изделия.

Выполнение исследования с помощью библиотек Python. Аналогичная работа по проектированию, обучению и тестированию нейронной сети была выполнена на языке программирования Python использованием библиотеки Keros [7]. При использовании библиотеки Keros была спроектирована нейронная сеть с применением Гребневой регуляризации. В качестве активационной применялась функция «tan» (гиперболического тангенса).

Спроектированная модель представляет собой персептрон, имеющий 20 входных нейронов, один выходной нейрон и один скрытый слой, состоящий из 65 нейронов. Для обучения нейросети применено 500 итераций (эпох) обучения.




Рис. 5. Зависимость прогнозируемого брака от параметра X11

Реализация обучения с использованием метода гребневой регуляризации нейронной сети активационной функции гиперболического тангенса (рис. 6–7).




Рис. 6. Результат тестирования нейронной сети в Python

```

**** ОЦЕНКА КАЧЕСТВА МОДЕЛИ ****

# Вычисление коэффициента детерминации
from sklearn.metrics import r2_score
r2 = r2_score(y_test, predictions)
print('r2=', r2)

r2= 0.615363723422959

```

Рис. 7. Оценка качества модели

Далее, с помощью метода «замораживания», проведено исследование полученных зависимостей между входными параметрами и процентом брака (рис. 8).




Рис. 8. Зависимости прогнозируемого процента брака от параметров X11, X12

Для оценки корректной работы спроектированных нейронных сетей использовалось тестирующее множество, состоящее из 100 примеров. Коэффициент детерминации результатов, полученных с помощью платформы Нейросимулятор 5 составил 68,4 %, спроектированных с использованием библиотек Keras – 61,5 %. Подобные результаты следует считать приемлемыми.

Заключение. Построены нейросетевые системы для прогнозирования результатов и выявления причин брака в промышленном производстве литейных стержней. Спроектированные нейросетевые модели учитывают 20 параметров регулирования которых позволяет снизить процент брака при реализации технологического процесса производства серийно выпускаемых изделий. Методом сценарного прогнозирования построены графики зависимостей прогнозируемого брака от изменения входных параметров. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать условия изготовления бракованной продукции, с целью недопущения их в технологическом процессе.

Нейросетевая система, спроектированная средствами Нейросимулятор 5 показала результаты лучше, чем нейросетевые системы, разработанные средствами библиотеки Keras.

Поддержка исследования. Исследование выполнено при поддержке гранта Российского научного фонда № 22–61–00096 (<https://rscf.ru/project/22-61-00096/>). Головным исполнителем гранта является Национальный исследовательский университет «МЭИ».

Библиографический список

1. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
2. Ясницкий Л.Н. Искусственный интеллект. Элективный курс: учебное пособие. М.: БИНОМ. Лаборатория знаний, 2011. – 197 с.
3. Галушкин А.И. Теория нейронных сетей. М.: ИПРЖР, 2000. 416 с.
4. Тарасова Н.А., Лялин В.М., Пантюхин О.В. Управление качеством изделий массового производства с применением теории нейронных сетей. Тула: Известия ТулГУ. Технические науки. Вып.2, 2011. – С 342-347.

5. Вдовин Р.А. Формирование технологических основ изготовления рабочих лопаток турбины ГТД: монография. Самара: Издательство Самарского университета, 2021. – 209 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.<https://pypi.org/project/keras/>
7. Ясницкий Л.Н. Метод фиктивных канонических областей в механике сплошных сред. Москва, 1992.

NEURAL NETWORK FORECASTING SYSTEM AND IDENTIFYING THE CAUSES OF MARRIAGE WHEN PRESSING GRAPHITE RODS

Svetlov Vladimir N.

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

The article describes the development of a neural network system for predicting the results and identifying the causes of defects in the industrial production of graphite rods. The system allows to identify with great accuracy the most significant parameters of the technological process used in the pressing of graphite rods, affecting the production of low-quality (defective) products.

Keywords: artificial intelligence, neural network technologies, forecasting, industrial production, graphite rod.

УДК 519.254

АНАЛИЗ ДАННЫХ И СОЗДАНИЕ СИСТЕМЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПТИМИЗАЦИИ ПРОЦЕССА ВЫПЛАВКИ ВЫСОКОПРОЧНОЙ СТАЛИ

Штейнле Денис Константинович

Ясницкий Леонид Нахимович

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

В статье представлено описание подбора классических регрессионных моделей машинного обучения для предсказания ударной вязкости стали выплавляемой в мартеновской печи. Данные модели позволяют выявлять основные тенденции влияния независимых признаков на целевой и на основании знаний этих закономерностей давать рекомендации по оптимизации технологического процесса.

Ключевые слова: процесс выплавки стали, химический состав, взаимозависимые процессы, прогнозирование механических свойств, параметры процесса выплавки, регрессионные модели.

Введение. Актуальность использования алгоритмов машинного обучения при выплавке высокопрочных сталей обуславливается возможностью снижения производственных затрат. Высокий процент брака при выплавке высокопрочных сталей, из-за растраты дорогостоящих легирующих элементов и электроэнергии, а также рекламационные издержки, вызванные низким качеством выплавляемого металла, отрицательно сказываются на стоимости стратегически важной продукции.

Большой набор разработанных на сегодняшний день алгоритмов машинного обучения вкупе с возможностью использования больших и при этом дешевых вычислительных мощностей позволяет исключить негативный человеческий фактор. Такая трансформация производства не требует закупки дополнительного дорогостоящего оборудования, высоких трудозатрат или привлечения дополнительных рабочих кадров.

Об эффективности применения подобного подхода говорят научные работы и статьи [1–6], освещающие удачный опыт применения алгоритмов машинного обучения в сталелитейной промышленности. При этом стоит отметить, что для схожих технологических процессов не существует универсального алгоритма, а описанных исследований использования машинного обучения для производства стали в мартеновских печах на реальных данных крайне мало.

Данная работа позволит в дальнейшем использовать обученные модели для корректировки химического состава сырьевого материала и технологических параметров, с целью снижения доли брака при выплавке металла на реально существующем производстве. Работа проведена на реальных данных одного из сталелитейных производств, по проведенным ранее выплавкам, собранным в датафрейм. Каждую выплавку характеризует 56 признаков, один из которых целевой.

Основной целью исследования является обеспечение возможности предсказания ударной вязкости выплавляемого в мартеновской печи металла с помощью моделей машинного обучения. Такие модели позволяют выявить основные закономерности процесса выплавки. Выявленные в результате моделирования знания, в свою очередь, позволяют дать рекомендации по улучшению качества выплавляемого металла.

Подготовка данных и разведывательный анализ. Первым этапом работы с данными послужила очистка данных от пропусков и выбросов. При обработке пропусков были отброшены наблюдения с неизвестными значениями целевого признака ударной вязкости, а также те строки, где не указаны значения более семи признаков. Остальные пропуски заполнялись центрированными величинами, в зависимости от типа распределения признака, определенного по гистограмме. В нормальных распределениях пропуски заменялись средним арифметическим, в логнормальных – медианными значениями. Работа с выбросами заключалась в анализе диаграмм типа «ящик с усами» созданных для каждого из признаков. Выявленные аномалии заменялись на медиану.

После обработки пропусков и выбросов был проведен разведывательный анализ, включающий разделение данных на тренировочную и тестовую выборки в соотношении семь к трем, нормализацию данных и замену категориальных

признаков на вновь спроектированные дискретные характеристики. Для исключения признаков снижающих качество моделей был применен метод «RFE» с рекурсивной оценкой полезности факторов для предсказания целевой переменной алгоритмом линейной регрессии. Данный метод шаг за шагом исключает по одному признаку с наименьшим весом в обученной модели. По итогу подготовки и разведывательного анализа данных было отобрано двадцать восемь независимых признаков. Данные были разбиты на два датафрейма: тренировочный объемом 326 строк и тестовый объемом 140 строк.

Проектирование, обучение и тестирование регрессионных моделей.

После проведения разведывательного анализа на тренировочной выборке было обучено десять моделей среди которых были линейная регрессия, kNN, дерево решений, комитет для регрессии, бэггинг, лес решений, стекинг, градиентный бустинг и адаптивный бустинг. Качество обученных моделей оценивалось по четырем метрикам: MAE, RMSE, MAPE и R^2 . Расчет метрик проводился как на тестовой, так и на тренировочной выборках. Все посчитанные метрики были собраны в отдельный датафрейм для сравнения. Наилучшими по уровню метрик были признаны модель стекинга объединяющая два разных алгоритма градиентного бустинга и линейный регрессор со стохастическим спуском (далее модель 1) со значением $R^2=0,496$ и модель градиентного бустинга CatBoost (далее модель 2) со значением $R^2=0,514$.

Для двух лучших моделей по тестовой выборке были составлены столбчатые диаграммы (рис. 1, 2), отражающие реальные и предсказанные значения ударной вязкости.




Рис. 1. Предсказанные и тестовые значения, модель 1




Рис. 2. Предсказанные и тестовые значения, модель 2

Оценка данных диаграмм показала, что обе модели при предсказании значительно завышают самые низкие значения целевого признака. Для корректировки моделей было проведено повторное обучение с увеличением весов значений целевого признака равным менее восемнадцати единиц. После этого была проведена повторная проверка метрик. Снижение коэффициента детерми-

нации R^2 для тестовой выборки составило 0,05 для модели 1 и 0,03 для модели 2. Признаков переобучения моделей не появилось.

Исследование предметной области. Из тестовой выборки были отображены три наблюдения с самыми низкими показателями ударной вязкости, а также создано одно новое наблюдение, где все значения равны медианным по каждому из признаков. Для четырех указанных выплавов на рис. 3-6 методом замораживания входных параметров [1] построены две группы графиков по скорректированным моделям 1 и 2. Каждый график соответствует определенному признаку и отображает зависимость целевой переменной от значения представленного фактора согласно тенденциям, выявленным при обучении модели. Значения факторов изменяются в отрезке между минимальным и максимальным значением в тестовой выборке. Ещё на графиках отображена линия брака на уровне 29кДж/м.кв. для понимания того, какие значения признака, согласно модели, выводят выплавку в категорию годных. Здесь же нанесены реальные значения целевого признака для каждой из бракованных плавок, а также маркеры предсказанных в данных точках значений.

Анализ данных графиков позволил выявить основные тенденции изменения ударной вязкости при изменении значений признаков, которые, как видно из рисунков, на качественном уровне совпали для медианной и бракованных выплавов. Исходя из оценки графиков отобраны два контролируемых признака с наиболее сильным влиянием на целевой признак для обеих моделей.

Согласно модели 1 зависимость ударной вязкости от содержания фосфора (рис. 3) является обратной для всех четырех образцов. Увеличение содержания фосфора с 0.007% до 0.011% приводит к снижению целевого признака на 16 кДж/м.кв. для образца 1, на 8 кДж/м.кв. для образца 2 и на 9 кДж/м.кв. для образца 3. Далее появляется слабая прямая зависимость целевого признака от содержания фосфора.




Рис. 3. Влияние содержания фосфора, модель 1

Зависимость ударной вязкости от содержания фосфора (рис. 4), согласно модели 2, до отметки содержания элемента примерно в 0.01% резко отрицательная для всех четырёх образцов. Около этой отметки показатель ударной вязкости для образцов 2 и 3 опускается ниже линии брака. После этого знак зависимости меняется на положительное и дальнейшее увеличение доли фосфора ве-

дет к плавному улучшению качества стали. При этом образец номер 3 на отметке 0.07 % вновь выходит из категории брака.




Рис. 4. Влияние содержания фосфора, модель 2

Согласно модели 1, увеличение содержания магния до 1% повышают ударную вязкость до максимально возможной для наблюдения с наименьшим целевым показателем (образец 1). Для медианного наблюдения, а также образцов 2 и 3 улучшение целевого признака до максимума происходит при увеличении доли марганца до 1,1%. После достижения пика ударная вязкость для всех четырех образцов начинает слабую стагнацию до 1,3% по марганцу. Далее происходит резкое снижение целевого признака.

Зависимость ударной вязкости в процессе увеличения значения содержания марганца, согласно модели 2, меняет знак на всех четырех образцах (рис. 6). Качество стали улучшается при увеличении содержания элемента до 1,15 %. Дальнейшее увеличение содержания марганца до 1,39 % приводит к снижению качества стали. По достижению данной отметки ударная вязкость пропадает. Образец 2 до уровня содержания марганца 1,3 % находится выше линии брака, образец 3 переходит в категорию брака при увеличении содержания легирующего элемента до 1,38 %.




Рис. 5. Влияние содержания марганца, модель 1




Рис. 6. Влияние содержания марганца, модель 2

Практические рекомендации и заключение. В процессе выполнения исследовательской работы была произведена подготовка данных, представляющих собой таблицу с параметрами выплавки металла. На отобранных признаках было обучено десять моделей регрессии, из которых были отобраны две наиболее точных.

В тестовую выборку было добавлено одно искусственно созданное наблюдение. Данное наблюдение было спроектировано посредством установки медианных значений по выборке для каждого из признаков.

Для двух откорректированных моделей были составлены графики по трем выплавкам с наименьшим значением целевого признака. Сюда же для сравнения результатов была добавлена спроектированная выплавка, общие тенденции графиков которой совпали с тенденциями графиков реальных выпливок. На основании анализа полученных графиков зависимостей ударной вязкости выплаваемого металла от его химического состава, предлагается выдерживать содержание фосфора в интервале не более 0,005%, а содержание марганца не более 1%. Данные показатели были подставлены в наблюдение с наименьшим целевым признаком (образец 1). Согласно модели 1 ударная вязкость для данного образца, с исправленными значениями, равна 29 кДж/м.кв., а для модели 2 — 30,24 кДж/м.кв., при норме 29 кДж/м.кв. Таким образом, рекомендацией для получения годной выплавки из самой низкокачественной, является изменение двух указанных параметров технологического процесса.

Поддержка исследования. Исследование выполнено 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. Интеллектуальные системы: М.: Лаборатория знаний, 2016. 221 с.
2. Мезенцев А.С., Ясницкий Л.Н. Нейросетевая модель для определения регламентных параметров технологического процесса переработки рудного сырья // Прикладная информатика. 2022. Т. 17. № 6. С. 56–67. DOI: 10.37791/2687-0649-2022-17-6-56-67
3. 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. 99-109. DOI: 10.37791/2687-0649-2023-18-6-99-109.

4. Ясницкий Л.Н., Голдобин М.А. Нейросетевое прогнозирование дефектов

1. производства металлургической продукции // Прикладная информатика. 2024. Т. 19. № 1. С. 109–120. DOI: 10.37791/2687-0649-2024-19-1-109-120.

5. Ghalati MK, Zhang J, ElFallah GMAM, Nenchev B, Dong H. Toward learning steelmaking—a review on machine learning for basic oxygen furnace process. MGEAdvances. 2023;1(1): e6. <https://doi.org/10.1002/mgea.6>.

6. Сафронов А.А., Ронков Л.В., Сукочев А.Ю., Лоскутов А.С., Москowej К.А., Лунев А.А. Применение цифровых технологий при выплавке и внепечной обработке стали: доклад. [Электронный ресурс]. Режим доступа:https://www.academia.edu/42995101/Применение_цифровых_технологии_при_выплавке_стали_ред.

7. Тлустенко С.Ф., Бибииков А. М., Журавель Л. В., Коптев А. А. Прогнозирование свойств конструкционных материалов и выбор оптимальных технологий их производства//Вестник Самарского государственного аэрокосмического университета. 2009. №3(19) С. 178–183.

8. Ямшинский М. М., Федоров Г. Е. Литейные и механические свойства жаростойких сталей//Литье и металлургия. 2015. №2. С. 17-23.

DATA ANALYSIS AND CREATION OF A MACHINE LEARNING SYSTEM TO OPTIMIZE THE HIGH-STRENGTH STEEL PRODUCTION PROCESS

Denis K. Shteinle

Perm State National Research University

Bukireva str., 15, Perm, Russia, 614068

HSE University

Str. Studencheskaya, 38, Perm, Russia, 614070

dkshhteinle@edu.hse.ru

The relevance of using machine-learning algorithms in the smelting of high-strength steels is due to the possibility of reducing production costs. The set of machine learning methods available today allows you to select and train a predictive algorithm that allows you to assess the quality of smelting in advance. The article describes the training and selection of machine learning models to predict the impact toughness of high-strength steel smelted in an open-hearth furnace. The data were taken from real production. For the selected StackingRegressor and CatBoost algorithms, graphs of the impact toughness dependencies on each of the independent features were constructed. For the observation describing the lowest quality smelting, it was proposed to maintain the phosphorus content at 0.005% percent, and the manganese content at 1%. These recommendations, according to both selected algorithms, raise the impact toughness index to an acceptable level.

Keywords: steelmaking process, chemical composition, interdependent processes, prediction of mechanical properties, smelting process parameters, regression models.

РАЗРАБОТКА ПРОГРАММНОГО СРЕДСТВА ДЛЯ РАСПОЗНАВАНИЯ ЗАДАНЫХ ОБЪЕКТОВ

*Кулик Сергей Дмитриевич, Ахметов Азат Фаридович,
Зинченко Александр Павлович*

Национальный исследовательский ядерный университет НИЯУ МИФИ,
115409, Россия, г. Москва, Каширское шоссе, 31
zap-02@mail.ru, sedmik@mail.ru, azat.akhmetov.1998@bk.ru

В статье представлено описание разработки программного средства для распознавания заданных объектов – БПЛА. Система содержит четыре алгоритма компьютерного зрения, которые могут быть использованы по отдельности в зависимости от окружающих условий, а именно – положения камеры, статичности изображения и погодных условий.

Ключевые слова: нейросетевые технологии, компьютерное зрение, распознавание объектов, сравнение моделей компьютерного зрения, нейрокомпьютерный интерфейс.

Введение. Компьютерное зрение является одной из самых прогрессивных и быстро развивающихся областей. По данным Grand View Research, размер мирового рынка компьютерного зрения в 2020 году оценивался в 11,32 миллиарда долларов, и ожидается, что совокупный годовой темп роста составит 7,3 % в период с 2021 по 2028 год. Вариантов использования компьютерного зрения с поддержкой ИИ почти бесчисленное множество, наиболее популярными из которых являются потребительские дроны, а также автономные и полуавтономные транспортные средства. Кроме того, благодаря недавнему прогрессу в компьютерном зрении, ИИ теперь необходим в различных отраслях, таких как образование, здравоохранение, робототехника, бытовая электроника, розничная торговля, производство, и более.

Распознавание заданных объектов (беспилотных летательных аппаратов (БПЛА)) является одной из актуальных и важных для изучения тем в настоящее время. Язык Python [1] может быть использован для этого. Системы, использующие нейросетевые подходы в компьютерном зрении, обеспечивают автоматизацию процесса охраны стратегически важных предприятий.

Данная работа поможет эффективно решать задачи нежелательного проникновения на охраняемые объекты и вести учёт попыток вторжения на территории предприятия, использующего систему компьютерного зрения.

Сбор данных происходил на открытых источниках и аугментации открытых наборов данных [2]. Основная цель работы – сравнение результатов работы четырёх алгоритмов компьютерного зрения в зависимости от начальных условий окружающей среды. Конечный результат – программное средство, способное в реальном времени отслеживать заданные объекты в пространстве.

Постановка задачи и формирование DataSet. Для разработки программного средства были выбраны четыре алгоритма компьютерного зрения:

1. YOLOv8.
2. Faster R-CNN.
3. Алгоритм Виолы-Джонса.

4. Алгоритм статичной камеры.

Алгоритмы 1 и 2 были обучены с помощью доступных наборов данных с использованием аугментации – простые геометрические преобразования: поворот изображения и симметрия.

Алгоритм 3 является алгоритмом классификации и использует каскады Хаара. Обучение классификатора происходило на открытом наборе данных.

Алгоритм 4 использует условия окружающей среды, а именно – камера должна находиться в неподвижном состоянии. Алгоритм не предполагает обучения и полностью детерминирован [3].

Разработка и тестирование программного средства (ПС). В качестве показателя эффективности распознавания была выбрана метрика метрикаIoU (IntersectionOver Union) [4]. Данная метрика используется чтобы определить верна ли предсказанная область – содержит ли она специальный объект. Площадь пересечения предсказанного бокса с gt боксом делится на площадь их объединения.

Предсказание считается TP (Truepositive), если IoU больше или равно заданного порога, а иначе полагается FP (Falsepositive).

Опираясь на работы [5, 6, 7, 8] была выполнена разработка требуемого ПС. Структурная схема программного средства представлена на рис. 1.

На рис. 2 представлен пример работы программного средства с выбранным алгоритмом YOLOv8.

На левой части рис. 2 видно, как детектируется первый БПЛА. На средней части рис. 2 видно, как детектируется БПЛА на заднем плане. Далее первый БПЛА взлетает с земли на некоторую, на правой части рис. 2 видно, как детектируется первый БПЛА, находясь примерно на 100 метров. Тестирование осложнено фактом отсутствия съёмок БПЛА (дронов) в хорошем качестве.

В табл. представлены результаты тестирования программного средства. Тестовая выборка формировалась [5] из полного набора данных в соотношении 70 к 30.




Рис. 1. Структурная схема работы программного средства



Рис. 2. Пример работы программного средства (YOLOv8)

Таблица

Результаты тестирования ПС

Архитектура нейронной сети	Особенности применяемых архитектур	Входные данные	IoU
YOLOv8	1.Применяется базовая сеть Darknet-53, которая показывает высокую точность детектирования, при этом имея меньшее количество операций над изображениями, чем ResNet.Также данная сеть имеет удвоенную скорость при одинаковой производительности с ResNet. 2.Используются дополнительные ограничительные рамки, которые игнорируют другие объекты, не попадающие в выбранный порог(используется значение 0,7)	Набор данных с Kaggle(2500 изображений БПЛА)	91,1%
Faster-RCNN	Усовершенствование существующей архитектуры, объединяя различные уровни методов для повышения точности детектирования: 1) <i>featurefusion, transferlearning</i> – для детектирования как крупных, так и мелких объектов; 2) <i>hardnegativemining</i> –для увеличения показателей точности моделей	Набор данных с Kaggle(2500 изображений БПЛА)	78,8%
Алгоритм Виолы–Джонса	Использование специфических признаков для выделения регионов, в которых могут находиться интересующие нас объекты	Набор данных с Kaggle(2500 изображений БПЛА)	46,4%
Алгоритм статичной камеры	Данный алгоритм использует возможности окружения, а именно – статичность камеры и, как следствие, возможность генерации «фона», относительно которого двигаются объекты. Данный алгоритм является экспериментальной разработкой и нуждается в оптимизации и доработке	Видеоряд со съемкой БПЛА из открытого источника	40,0%

Применяя полученный опыт и опираясь также на [9, 10] был успешно разработан нейрокомпьютерный интерфейс в виде ПС и устройства как средство сбора и хранения данных этого интерфейса на основе TGAM1, Arduino

UNO и сухих электродов. ПС позволяет [9] сохранять и визуализировать сигналы в режиме реального времени, так как это важно для эффективного анализа полученных экспериментальных данных.

Заключение. Предложена структура программного средства, описаны её составные части. Рассмотрена работа программного средства. Разработаны необходимые алгоритмы для программного средства.

Выполнена проверка работы программного средства на тестовом наборе данных, которая показала его работоспособность, т.е. возможность выполнять поставленные перед ним задачи.

Таким образом, была успешно выполнена требуемая разработка программного средства, решающего такие задачи компьютерного зрения, как детекция, сегментация, трекинг и распознавание объектов на изображении и в видео потоке.

Проведена оценка эффективности разработанного ПС. Достигнутые показатели: наибольшее значение показателя IoU имеет реализованный алгоритм YOLOv8 – 91,1 %.

Полученный опыт был успешно применен для разработки нейрокомпьютерного интерфейса.

В дальнейшем возможно усовершенствование реализованного программного средства, например, добавление расширенного функционала, работа над дизайном программного средства.

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 [Электронный ресурс]. 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) руков.: Кулик С.Д. – 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.: Издательский дом «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. №4. URL: <https://cyberleninka.ru/article/n/sravnitelnyy-analiz-metodov-detektirovaniya-obektov-na-radiolokatsionnyh-izobrazheniyah-pri-pomoschi-neyronnyh-setey> (дата обращения: 21.12.2023).
9. Зинченко А.П. Разработка прототипа программного средства для сбора и хранения данных специального нейрокомпьютерного интерфейса на основе TGAM1, ArduinoUNO и сухих электродов /Отчет о НИР (рукопись) руков.: Кулик С.Д. – М.: НИЯУ МИФИ, 2024. – 30 с.
10. Применение нейрокомпьютерных интерфейсов для реабилитации и улучшения условий жизни пациентов с нарушениями моторных функций нервной системы Цулейскири Е.Г. [сайт] // URL: <https://interagro.donstu.com/wp-content/uploads/2022/12/203-206.pdf> (Дата обращения 20.04.2024).

DEVELOPMENT OF A SOFTWARE TOOL FOR RECOGNIZING SPECIAL OBJECTS

Kulik Sergey Dmitrievich, Akhmetov Azat Faridovich, Zinchenko Alexandr Pavlovich

National Research Nuclear University MEPhI, 31 Kashirskoye Highway,
Moscow, Russia, 115409

sedmik@mail.ru, azat.akhmetov.1998@bk.ru, zap-02@mail.ru

The article describes the development of a software tool for the recognition of special objects – UAVs. The system contains four computer vision algorithms that can be used separately depending on the surrounding conditions, namely, camera position, static image and weather conditions. The software tool allows you to accurately determine the presence of special objects in the frame. In real time, using a software tool, the task of not only recognizing, but also tracking a special object can be solved. The result of this work is a comparison of base-model and data-driven algorithms.

Keywords: neural network technologies, computer vision, object recognition, comparison of computer vision models, neurocomputer interface.

УДК 004.8:621.313

РОЛЬ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРЕДИКТИВНОМ ОБСЛУЖИВАНИИ ПРОМЫШЛЕННОГО ПРОИЗВОДСТВА: ИССЛЕДОВАНИЕ НА ПРИМЕРЕ РЕДУКТОРОВ ВЕТРОУСТАНОВОК

Аль Уатик Хассан Саидович, Пронин Сергей Петрович

ФГБОУ ВО «Алтайский государственный технический университет»

656038, Россия, г. Барнаул, пр. Ленина, 46

sppronin@mail.ru, alh@dr.com

В статье представлено описание системы предиктивного обслуживания редукторов ветроустановок с применением ИИ. Система использует алгоритмы машинного обучения и данные IoT, что позволяет сократить время простоя и оптимизировать графики обслуживания.

Ключевые слова: Искусственный интеллект, предиктивное обслуживание, редукторы, ветроэнергетика, машинное обучение, случайный лес, Интернет вещей, промышленное производство, граничные вычисления.

Введение. Искусственный интеллект приобретает всё большее значение в различных отраслях, от автоматизации процессов до оптимизации принятия решений в бизнесе и экономике. В промышленном производстве ИИ оказывается особенно ценным в предиктивном обслуживании, где он помогает предотвращать отказ оборудования и продлевать срок службы машин.

В данной статье рассматривается роль ИИ в предиктивном обслуживании ветроэнергетических установок, критического компонента сектора возобновляемой энергии. Ветроэнергетические установки, особенно их редукторы, подвержены эксплуатационным сбоям, которые могут приводить к дорогостоящим

простоям и расходам на обслуживание. Интегрируя технологии ИИ, такие как машинное обучение и устройства IoT, можно разработать системы предиктивного обслуживания, повышающие операционную эффективность и устойчивость в промышленном производстве.

ИИ в промышленном производстве: предиктивное обслуживание.

Предиктивное обслуживание – это подход, основанный на ИИ, который позволяет в реальном времени отслеживать состояние машин и предсказывать возможные отказы до их возникновения. Это достигается путём анализа больших данных, собираемых датчиками, и использования моделей машинного обучения для выявления закономерностей, связанных с деградацией оборудования.

В контексте ветроэнергетических установок редуктор является критическим компонентом, подверженным износу. Традиционные методы обслуживания часто опираются на реактивные стратегии, которые решают проблемы только после возникновения отказа, что ведёт к дорогостоящим простоям. Предиктивное обслуживание на основе ИИ, напротив, помогает компаниям переходить к проактивному подходу, минимизируя прерывания в производстве.

Модели машинного обучения для предиктивного обслуживания.

Модели машинного обучения играют ключевую роль в анализе данных с датчиков ветроэнергетических установок. В данном исследовании использовался классификатор случайного леса для предсказания неисправностей редуктора на основе анализа вибрационных данных, собранных с датчиков турбин. Модель была обучена на синтетических данных, имитирующих различные условия отказов, такие как нормальная работа, трещины в шестернях и поломки зубьев.

Алгоритм случайного леса строит несколько деревьев решений на этапе обучения. Прогноз леса выражается следующим образом:

$$\hat{y} = \frac{1}{N_T} \sum_{i=1}^{N_T} T_i(X)$$

где $\hat{y}$ – это прогнозируемый результат, X – это матрица входных признаков, N_T – количество деревьев, а $T_i(X)$ – прогноз i -го дерева решений [1]. Агрегация этих прогнозов помогает повысить точность и уменьшить переобучение.

Для повышения производительности модели была проведена настройка гиперпараметров, оптимизируя ключевые параметры, такие как количество оценщиков, глубина деревьев и минимальное количество образцов для разбиения. Окончательная модель показала высокую точность в различении нормальных и неисправных состояний редуктора.

Интеграция IoT для мониторинга в реальном времени. Одной из ключевых проблем в предиктивном обслуживании является обработка данных в реальном времени. Устройства IoT, установленные на ветроэнергетических установках, непрерывно собирают данные с датчиков, которые затем обрабатываются с помощью моделей ИИ для предоставления прогнозов неисправностей в реальном времени. Были интегрированы решения на основе граничных вычислений, чтобы уменьшить задержки, обеспечивая мониторинг и принятие реше-

ний в реальном времени без необходимости отправки всех данных на централизованные серверы.

Эта интеграция не только сокращает время обработки данных, но и обеспечивает своевременное оповещение команд технического обслуживания, что позволяет им вмешиваться до того, как мелкие проблемы перерастут в серьёзные неисправности. Платформа на основе IoT демонстрирует практическое применение ИИ в повышении операционной эффективности промышленных систем [2].

Время, необходимое для анализа в реальном времени, T_r , минимизируется благодаря граничным вычислениям. Оно может быть выражено как:

$$T_r = T_{data} + T_{processing} + T_{communication}$$

где T_{data} – это время, затраченное на сбор данных, $T_{processing}$ – время обработки данных на границе, и $T_{communication}$ – время передачи соответствующих результатов. Уменьшая $T_{communication}$, общее время для действий в реальном времени значительно сокращается.

Экономические и операционные преимущества. Внедрение систем предиктивного обслуживания на основе ИИ на ветроэнергетических станциях приносит значительные экономические и операционные преимущества:

- Сокращение простоя: Предсказывая возможные отказы редуктора заранее, система минимизирует незапланированные простои, обеспечивая непрерывное производство энергии.
- Экономия затрат: Проактивное обслуживание сокращает потребность в аварийных ремонтах и оптимизирует графики обслуживания, что ведёт к снижению эксплуатационных расходов.
- Продление срока службы оборудования: Предиктивные модели помогают выявлять износ до того, как он приведёт к серьёзным повреждениям, что продлевает срок службы компонентов турбин.
- Повышение энергоэффективности: Турбины, работающие с меньшими перебоями, максимизируют производство энергии, способствуя более устойчивой и прибыльной работе.

Эти преимущества показывают, как ИИ может революционизировать промышленное производство, делая его более предсказуемым, эффективным и экономичным.

Будущие перспективы и вызовы. Несмотря на перспективное применение ИИ в предиктивном обслуживании, остаются некоторые проблемы. Одна из ключевых задач – это необходимость обширных реальных данных для валидации моделей, разработанных на основе синтетических данных. Кроме того, интеграция ИИ с устаревшими системами в производственных средах может быть сложной и дорогостоящей.

Будущие исследования должны сосредоточиться на совершенствовании моделей машинного обучения за счёт использования более продвинутых алгоритмов, таких как глубокое обучение, для повышения точности прогнозов неисправностей. Также следует продолжить изучение экономического и экологи-

ческого влияния систем обслуживания на основе ИИ для количественной оценки их долгосрочных преимуществ [3].

Заключение. Роль ИИ в промышленном производстве, особенно в предиктивном обслуживании, является преобразующей. Это исследование демонстрирует, как ИИ может эффективно использоваться для предсказания неисправностей редукторов ветроэнергетических установок, сокращая время простоя, оптимизируя затраты и увеличивая операционную эффективность. По мере того, как технологии ИИ продолжают развиваться, их применение в промышленных условиях станет ещё более распространённым, способствуя улучшению как производительности, так и устойчивости.

Библиографический список

1. Breiman, L. Random forests // Machine Learning. 2001. Vol. 45, No. 1. Pp. 5–32. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1023/A:1010933404324>.
2. Gubbi, J., Buyya, R., Marusic, S., Palaniswami, M. Internet of Things (IoT): A vision, architectural elements, and future directions // Future Generation Computer Systems. 2013. Vol. 29, No. 7. Pp. 1645–1660. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1016/j.future.2013.01.010>.
3. Phillips, A.W., Rogers, J.D. Machine learning for wind turbine condition monitoring: A review // Renewable Energy. 2020. Vol. 145. Pp. 640–653. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1016/j.renene.2018.10.047>.

THE ROLE OF ARTIFICIAL INTELLIGENCE IN PREDICTIVE MAINTENANCE FOR INDUSTRIAL PRODUCTION: A STUDY ON WIND TURBINE GEARBOXES

HassanS. Al Ouatiq, Pronin Sergey Petrovich

Altai State Technical University,
Lenin Ave., 46, Barnaul, Russia, 656038
alh@dr.com, sppronin@mail.ru

The project focuses on the development and implementation of a predictive maintenance system for wind turbine gearboxes using artificial intelligence (AI). By integrating machine learning algorithms, specifically the random forest classifier, and real-time data from Internet of Things (IoT) devices, the system predicts potential failures in critical components of wind turbines. This allows for proactive maintenance, reducing unplanned downtime and optimizing operational efficiency. The AI-based solution enhances the reliability of wind energy production, demonstrating significant economic and operational benefits in industrial environments by minimizing repair costs, extending equipment life, and improving overall energy efficiency.

Keywords: artificial intelligence, predictive maintenance, gearboxes, wind energy, machine learning, random forest, Internet of Things, industrial production, edge computing.

ПОСТРОЕНИЕ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ НА БАЗЕ МАШИННОГО ОБУЧЕНИЯ В УСЛОВИЯХ СЕРИЙНОГО ПРОИЗВОДСТВА

Ясницкий Виталий Леонидович, Мезенцев Алексей Сергеевич

Пермский национальный исследовательский политехнический университет
614068, Россия, г. Пермь, Комсомольский проспект, 29
yasnitskiy@mail.ru, mezentsevas@mail.ru

В статье представлено описание разработки рекомендательной системы, целью применения которой в серийном производстве является оптимизации производственных процессов, решение задачи прогнозирования качества, определения значимости технологических параметров, влияющих на образование брака.

Ключевые слова: архитектура программных средств, обработка данных, рекомендательные системы, мониторинг технологического оборудования, искусственный интеллект, нейросетевая модель, прогнозирование брака

Введение. Целью применения в серийном производстве рекомендательных систем на базе технологии машинного обучения является решение задачи прогнозирования качества выходных изделий. Задача является актуальной, поскольку подбор оптимального сочетания производственных параметров представляет собой сложную задачу для технолога, а в случае возникновения брака удлиняется производственный цикл. Задача решается с помощью создания рекомендательной системы на основе компьютерного моделирования и встраивания системы в производственный процесс предприятия.

Выбор архитектуры нейронной сети и процесс обучения. Обучение искусственной нейронной сети произведено с помощью инструментального средства «Нейросимулятор»-5.0» [1, 2, 3, 4]. Данный сервис позволяет создать логическое ядро системы, в основе которого лежит нейронная сеть. Выбор типа нейронной сети происходит на этапе обучения. Датасет для обучения представляет собой множество примеров изготовления изделий, включающего входные параметры модели (параметры технологического процесса, всего более 60) и выходные параметры модели (результаты контроля качества изготавливаемых изделий). Для генерации гиперповерхности нейронной сети используется алгоритм упругого обратного распространения ошибки (*Resilientbackpropagation*).

Выбор метрик оценки. При выборе метрик оценки разработчики руководствовались бизнес-логикой: разрабатываемый сервис решает задачу ресурсоемкого производства, что обусловлено большой стоимостью ошибки за счет высокой себестоимости каждой детали. Поэтому логично предположить, что метрика *Recall* имеет больший вес: показывает, сколько объектов среди тех, ко-

торые были идентифицированы признаком «брак», действительно таковыми являлись. Следующим шагом необходимо откалибровать соотношение порога принятия решений с метриками *Precision* и *Recall*. Как правило, в процессе обучения модели происходит одновременный рост обеих метрик. В случае, если выставить низкий порог, модель будет пропускать лишние образцы, которым модель дала достаточно баллов для прохода через порог, но также будет попадать больше образцов нужного класса, при которых модель сомневалась. Для добавления предпочтения между *Precision* и *Recall* выполняется балансировка с помощью *F*-меры [5].

Также в условиях производства аналитики данных периодически сталкиваются с ситуацией дисбаланса классов первичной выборки: в этом случае сложно понять, что вероятность, которую предсказывает модель, соответствует реальному распределению классов, поскольку используемые нейронные сети являются неоткалиброванными. Для решения задачи калибровки используются параметрическая калибровка Платта [6].

Работа с данными. В условиях производства часто приходится сталкиваться с высоким зашумлением исходных данных, заключающийся в большом количестве выбросов и противоречий статистической информации. Выбросы (отклонения) часто связаны как с человеческим фактором, так и неконсистентностью данных, полученных из разных источников (различных баз данных, сигналов датчиков и т.д.). Для работы с выбросами в случае высокого зашумления исходных данных часто используется подход визуализации с помощью диаграммы размаха (*Boxplot*). Однако, специфика прикладной области потребовала более гибкий подход предварительной обработки данных, для чего использован *ML*-фильтр, в основе которого лежит отдельная нейронная сеть: двухслойный персептрон с сигмоидными активационными функциями, что также позволило работать с нелинейностью данных.

Оценка значимости. Для оценки значимости входных параметров реализован алгоритм, в основе которого лежит гипотеза о том, что в случае исключения параметра из обучающего множества погрешность обучения (валидации, тестирования) будет тем выше, чем выше значимость входного параметра, за которым был закреплён удаленный нейрон.

Прогнозирование. Генерация сценариев технологического процесса используется в случае модернизации производства. Так для нейронной сети фиксируется один из входных параметров, после чего нейронная сеть генерирует прогноз образования дефектов и брака. Такая генерация сценариев позволяет выявлять закономерности моделируемых производственных процессов. Строя зависимости влияния управляющего параметра на качество изделия (выход нейронной сети) строится прогноз «Что будет, если».

Системная архитектура программного решения. В качестве системного дизайна выбрана трехуровневая сервис-ориентированная архитектура. Дан-

ный подход позволяет изолировать слой данных от слоя программной логики и при этом поставлять систему как сервис без критического влияния на остальные программные компоненты. Архитектура хранения данных также представляет собой набор разделенных информационных хранилищ: база данных, база прецедентов и база правил, обмен данными реализован посредством API-протокола.

Функциональная архитектура. В основе рекомендательной системы лежит сервис-ориентированная архитектура, функциональными блоками которой являются:

1. Блок обработки данных, поставляемых датчиками оборудования;
2. Блок ввода сценариев производства, при котором происходит получение производственного задания (информация о технологических параметрах);
3. Блок режима планирования, при котором происходит расчет различных сценариев работы оборудования и выдача оптимального технологического режима.

Интеграция в технологический процесс. Система функционирует на операционном уровне корпоративного прикладного программного обеспечения, на котором осуществляется прогнозирование и управление свойствами продукции, таким образом рекомендательная система встраивается в общий информационный ландшафт и выполняет задачу управления качеством выпускаемых изделий, осуществляет поиск отклонений от заданных параметров выпускаемой продукции до момента, когда такие отклонения могут привести к браку.

Заключение. Описанный опыт построения рекомендательных систем на базе машинного обучения целесообразно использовать при построении программных средств, при этом важно:

- выбрать архитектуру решения, учитывающую информационную безопасность исходных данных обучения, что может быть реализовано через многослойность хранения данных;
- предусмотреть обслуживаемость и масштабируемость системы, для чего используется микросервисная архитектура;
- правильно выбрать метрики оценки качества машинного обучения модели, что обеспечивает корректность расчета прогнозных сценариев;
- реализовать предобработку данных в случае проблемы их зашумления (неконсистентности, перекосов выборки), одним из решений является разработка специализированного фильтра данных на базе отдельной нейронной сети.

Также, при построении системы бывает важно учитывать вероятность замещения компонентов, например в случае, если предприятие реализует стратегию импортонезависимости программных средств, что обуславливает целесообразность независимой от внешних библиотек программной разработки.

Библиографический список

1. 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 <https://cloud.mail.ru/public/7sJ9/ndL4g1iFX>
2. 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=Journal of Applied Informatics. 2023. Т.18. № 6. С. 109-119. DOI: 10.37791/2687-0649-2023-18-6-109-119
3. Ясницкий Л.Н., Мезенцев А.С., Ясницкий В.Л. Определение регламента на технологические и сырьевые параметры изготовления серийно выпускаемых изделий // Математические методы в технологиях и технике. 2023. № 8. С. 21-24. DOI 10.52348/2712-8873_MMTT_2023_8_21
4. L. N. Yasnitsky, V. M. Gruzman, S. V. Martynenko and A. S. Mezentsev, "Prediction of Steel Articles Mechanical Properties Through Raw Stock Chemical Composition and Smelting Parameters," 2023 5th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA), Lipetsk, Russian Federation, 2023, pp. 813-816, doi: 10.1109/SUMMA60232.2023.10349589. <https://ieeexplore.ieee.org/document/10349589>
5. Частикова В.А., Лях А.Р. Методы машинного обучения в задачах балансировки данных // Электронный сетевой политехнический журнал «Научные труды КУБГТУ» 2021. № 4. УДК: 004.056.5
6. Platt, John et al. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. Advances in large margin classifiers, 10(3): 61–74, 1999.

CONSTRUCTION OF RECOMMENDATION SYSTEMS BASED ON MACHINE LEARNING IN CONDITIONS OF SERIAL PRODUCTION

Vitaly L. Yasnitskiy, Alexey S. Mezentsev

Perm Technical University,
614068, Russia, Perm, Komsomolsky Prospect, 29, Perm, Russia, 614068
yasnitskiy@mail.ru, mezentsevas@mail.ru

The article describes the development of a recommendation system, the purpose of which in mass production is to optimize production processes, solve the problem of predicting quality, determine the significance of technological parameters affecting the formation of defects.

Keywords: software architecture, data processing, recommendation systems, monitoring of technological equipment, artificial intelligence, neural network model, prediction of defects.

НЕЙРОСЕТЕВОЙ КЛАССИФИКАТОР ДЛЯ ОБНАРУЖЕНИЯ ФАЛЬСИФИЦИРОВАННЫХ КОРМОВ

Шереметьева Анастасия Сергеевна

Кубанский государственный аграрный университет имени И.Т. Трубилина,
350044, Россия, г. Краснодар, ул. Калинина, 13
nastia.scheremetjeva@yandex.ru

Полушин Алексей Александрович

Кубанский государственный аграрный университет имени И.Т. Трубилина,
350044, Россия, г. Краснодар, ул. Калинина, 13
polushin2004@mail.ru

Сухно Игорь Владимирович

Кубанский государственный аграрный университет имени И.Т. Трубилина,
350044, Россия, г. Краснодар, ул. Калинина, 13
sukhno_igor@mail.ru

Смышляев Никита Александрович

ООО "Фидэксперт",
352701, Россия, г. Тимашевск, ул. Транспортная, 10
n.smyshlyayev@feedexpert.ru

Абраменко Виталий Анатольевич

ИП Абраменко В.А., г. Тимашевск
4828646@mail.ru

В статье рассказывается о создании нейросетевого классификатора, который может выявлять фальсификации в кормах. Система точно определяет некачественный корм по фотографиям, сделанным под микроскопом.

Ключевые слова: нейросетевой классификатор, нейросеть, фальсификация корма, корма.

Введение. Фальсифицированные корма составляют значительную долю на рынке, поскольку замена части ингредиентов на более дешёвые позволяет снизить себестоимость продукции. Чаще всего производители заменяют самый ценный компонент корма – белок и его источники. Для фальсификации используются как органические, так и неорганические компоненты. Органические компоненты включают растительные корма, такие как горох и люпин, а также отходы производства, например, перьевую муку, щетину и шкуры. Неорганические компоненты включают карбамид, сульфат аммония, песок и опилки [1,2]. Из-за разнообразия форм фальсификации её сложно выявить. Современные методы определения фальсификации, такие как методы Къельдаля и Барнштейна для определения белка, методы спектроскопии и ПЦР, имеют узкую направленность [3]. Например, для определения примесей животного происхождения в рыбной муке используется тест на выявление белков жвачных.

Наиболее универсальным способом является прямой метод двухступенчатого микроскопического анализа, который позволяет обнаружить любые виды примесей. Однако качество анализа зависит от коллекции стандартных образцов и опыта исследователя [4]. Человеческий фактор может снизить точ-

ность анализа, поэтому предлагается использовать нейронные сети в качестве классификатора изображений. Натренированная нейросеть может с высокой точностью определить фальсификацию [5].

В качестве исходных данных использовались материалы для производства кормов, сами корма и вещества, используемые для их подделки. Основная задача исследования заключалась в разработке, обучении и тестировании нейросетевого классификатора на основе этих данных. Созданную нейросеть проверили на способность выявлять закономерности между поддельными и подлинными образцами. Итогом работы стал нейросетевой классификатор, способный обнаруживать поддельные корма. На основе него была разработан программный продукт для ПК.

Постановка задачи и формирование DataSet. Объектом анализа выступают корма: рыбная мука от различных производителей, мясная мука, комбикорма различных составов, концентрированные растительные корма. Образцы должны быть подготовленные к анализу, то есть, измельчены до состояния порошка. К чистым кормам добавляется мочевины в четырёх концентрациях: 2, 4, 6 и 8%.

Входными данными для нейросети служат микрофотографии образцов. Точность классификации зависит от количества и качества фотографии, поэтому требуется не менее 2-х изображений одного образца при различных параметрах освещения. Фотографии были предварительно сконвертированы в формат PNG разрешением 2592x1944 пикселя с сохранением всех трёх цветовых каналов (RGB, 8 бит на канал).

Всего было подготовлено 202 фотографии фальсифицированных образцов и 220 фотографии чистых кормов. На этапе проектирования нейросети использовалось 59 фотографий фальсифицированных образцов и 59 фотографий чистых, из которых 100 составляли тренировочную часть, а 18 валидационную. На этапе обучения датасет составлял 143 фотографии фальсифицированных образцов и 161 фотография чистых кормов и был разбит на тренировочную часть (суммарно 256 образцов) и валидационную (48 образцов).

Проектирование, обучение и тестирование нейросети. В качестве сети классификатора была выбрана свёрточная нейросеть. Проектирование выполнялось с помощью фреймворка PyTorch.

Сконструированная нейросеть содержала 12989714 тренируемых параметров. Размер батча составлял 50 изображений. Обучение происходило в течение 350 эпох. На каждой итерации тренировочного цикла из каждого образца выбирался случайный регион 1024x1024 пикселя, уменьшался до 256x256 пикселей методом билинейной интерполяции, после чего случайным образом зеркально отражался по вертикали либо горизонтали.

На 340-й эпохе был получен результат 98 % точности на тренировочной выборке и 82 % на валидационной. На рис. 1 представлен график, демонстрирующий течение обучения. На графике изображены две кривые соответствующие точности определения фальсификации тренировочной и валидационной выборки. На рис. 1 видно, что в течение обучения повышается точность определения с увеличением количества эпох.



Рис. 1. Ход обучения нейронной сети

После увеличения базы данных образцов и датасета размер батча был уменьшен и составил 16 изображений, а обучение проводилось в течение 1800 эпох. Оптимальный результат был получен на 1050 эпохе. Точность классификации на тренировочной выборке составила 95,7%, на валидационной – 87,5% для одного региона. На рис. 2 представлен ход обучения после уменьшения размера батча.




Рис. 2. Ход обучения нейронной сети в течение 1800 эпох

На основе данной нейросети был создан экспериментальный классификатор, точность которого была дополнительно повышена путём сравнения предсказаний нейросети для восьми случайно выбранных регионов входного изображения. В случае, если все предсказания для этих восьми регионов совпадают, и обладают достаточной достоверностью (предсказывается от 85% вероятность того или иного класса), весь образец относится к данному классу. Если же наблюдается различие в предсказаниях для разных регионов одного и того же изображения, или же предсказания не обладают достаточно высокой достоверностью, образец помечается как не классифицируемый. Это позволило полу-

чить точность классификации свыше 99% для порядка 80% образцов, выделив в отдельную категорию остальные 20% образцов, с классификацией которых нейронная сеть испытывает сложности.

Исследование предметной области. Для проверки работы нейронной сети был проведён натурный эксперимент. Корма для исследования были предоставлены компанией «ФИДЭКСПЕРТ» [6]. Образцами послужили кукурузный глютен в чистом виде и с примесями, белковая смесь в чистом виде, рыбная мука, а также фальсифицированные кормовые дрожжи. Нейросеть успешно опознала чистые образцы белковой смеси и кукурузного глютена. Несмотря на то, что изображений дрожжей не было в датасете нейросеть выдала хороший результат, определив наличие в них фальсификации с точностью в 96,7 %. На рис. 3 изображен интерфейс программы с изображением кормовых дрожжей.




Рис. 3. Интерфейс программы с изображением кормовых дрожжей

Образцы фальсифицированного кукурузного глютена тоже были успешно опознаны, но в случае с рыбной мукой нейросеть выдала результат 50 на 50.

Таким образом, при проверке классификатор показал хороший результат, который позволяет сделать вывод о работоспособности модели в условиях настоящего производства.

Заключение. В результате исследования сконструирован нейросетевой классификатор способный определять наличие фальсификации в кормах.

Для проектирования нейросетевой модели была создана база данных из образцов кормов. Нейросеть содержит 12989714 тренируемых параметров. На основе данных полученных в процессе обучения были построены графики, на которых виден высокий результат точности определения фальсификации. Натренированная нейросеть послужила основой создания программного продукта. Был разработан интерфейс программы, на котором видно изображение исследуемого корма. Был проведён натурный эксперимент, который показал хорошие результаты.

Исходя из итоговых результатов, система может использоваться в качестве быстрого теста на фальсификацию для заводчиков. Однако для корректной работы требуется расширение базы данных кормов и увеличение тренировочного набора изображений.

Библиографический список

1. Фоменко П.А., Богатырева Е.В. Причины фальсификации сырого протеина в кормах и способы ее выявления // Молочнохозяйственный вестник. 2022. №1 (45). URL: <https://cyberleninka.ru/article/n/prichiny-falsifikatsii-syрого-proteina-v-kormah-i-sposoby-ee-vyyavleniya> (дата обращения: 11.09.2024).
2. Донник И. М., Лошманова А. Ю., Беспмятных Н. Н. Показатели питательности рыбной муки и способы ее фальсификации // АВУ. 2012. №9 (101). URL: <https://cyberleninka.ru/article/n/pokazateli-pitatelnosti-rybnoy-muki-i-sposoby-ee-falsifikatsii> (дата обращения: 11.09.2024).
3. Кудинова, Н. А. Методы выявления фальсификации сухих животных кормов / Н. А. Кудинова, А. В. Аристов, А. М. Кудинова // Ветеринарно-санитарные аспекты качества и безопасности сельскохозяйственной продукции : Материалы VI Международной научно-практической конференции, посвящённой 110-летию ФГБОУ ВО «Воронежский государственный аграрный университет имени Императора ПЕТРА I», Воронеж, 25 марта 2022 года. – Воронеж: Воронежский государственный аграрный университет им. Императора Петра I, 2022. – С. 139-141. – EDN VJZHIX.
4. Богомолов, В. В. Фальсификация кормов: проблемы и решения / В. В. Богомолов, Е. Я. Головня // Контроль качества продукции. – 2017. – № 3. – С. 9-12. – EDN YFZZKF.
5. 6. The fishmeal adulteration identification based on microscopic image and deep learning / G. Jie, L. Jing Liu, K. Xianrui [и др.] // Elsevier : электронный журнал. – URL: <https://www.sciencedirect.com/science/article/abs/pii/S0168169922002915>. – Дата публикации: July 2022.
6. ООО «ФИДЭКСПЕРТ». [Электронный ресурс]. Режим доступа: <https://feedexperto.agroserver.ru/>

NEURAL NETWORK CLASSIFIER FOR DETECTING ADULTERATED FEED

Sheremeteva Anastasia S.,

Kuban State Agrarian University named after I.T. Trubilin,
350044, Russia Krasnodar, str. Kalinina, 13
nastia.scheremetjeva@yandex.ru

Polushin Alexey A.

Kuban State Agrarian University named after I.T. Trubilin,
350044, Russia Krasnodar, str. Kalinina, 13
polushin2004@mail.ru

Sukhno Igor V.

Kuban State Agrarian University named after I.T. Trubilin,
350044, Russia Krasnodar, str. Kalinina, 13
sukhno_igor@mail.ru

Counterfeit feeds make up a significant share of the market, since replacing some of the ingredients with cheaper ones allows you to reduce the cost of production. Due to the variety of forms of falsification, it is difficult to detect. The results of the analysis are influenced by human factors and the test method. It is proposed to use neural networks as an image classifier. A trained neural network can detect falsification with high accuracy. As a result of the study, a neural network classifier was constructed that is capable of detecting the presence of adulteration in feed. To design a neural network model, a database of 422 images of feed samples was created. The classification accuracy on the training set was 95.7%, which is a good result. The neural network served as the basis for the creation of the software product.

Keywords: neural network classifier, neural network, falsification of feed, feed.

КОМБИНАЦИЯ НЕЙРОННОЙ СЕТИ И МАТЕМАТИЧЕСКОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ НАПРЯЖЕНИЯ МИКРОБНЫХ ТОПЛИВНЫХ ЭЛЕМЕНТОВ

Медведев Иван Андреевич, Корнаухова Мария Анатольевна

Волгоградский государственный университет,
400062, Россия, г. Волгоград, пр. Университетский, 100
medvedev2000v@gmail.com, mariya_kornaukhova@volsu.ru

В данной работе представлены результаты комбинирования результатов математической модели прогнозирования параметров микробных топливных элементов с искусственной нейронной сетью. Полученные результаты позволяют сделать вывод, что данная комбинация позволяет более эффективно учитывать сложные процессы МТЭ.

Ключевые слова: искусственная нейронная сеть, микробный топливный элемент, биохимическое потребление кислорода.

Введение. Прогнозирование биохимического потребления кислорода за 5 дней (БПК₅) для биоразлагаемых органических веществ – важная задача в экологии и водоснабжении, так как этот показатель помогает оценить степень загрязнения водоемов и эффективность очистных сооружений. Искусственные нейронные сети (ИНС) могут быть эффективным инструментом для решения этой задачи [1]. Использование ИНС для прогнозирования БПК₅ может значительно улучшить эффективность управления водными ресурсами и мониторинга состояния экосистем. Биоразлагаемые органические вещества являются важными компонентами окружающей среды, так как они участвуют в процессах разложения органических остатков и обеспечивают питательными веществами почву и воду. Определение состава БОВ является ключевым для оценки состояния окружающей среды и разработки эффективных методов очистки вод. Значительный интерес к исследованиям нейросетевых технологий в определении БОВ вызван эксплуатацией микробных топливных элементов (МТЭ) для очистки сточных вод, содержащих загрязнения органической природы, которые окисляются аэробным биохимическим способом за период в пять дней и выражаются количественно в значениях БПК₅. Способ выявления концентрации нетоксичных биоразлагаемых органических веществ в водах с использованием МТЭ основан на линейной зависимости общего заряда и концентрации БПК₅ [3, 4]. На основе напряжения, вырабатываемого с помощью МТЭ, время измерения БПК можно сократить до 4 или даже до 0,5 суток в зависимости от концентрации органических веществ в воде, допуская ошибку определения БПК₅ в пределах 10% [3].

Для дальнейшего сокращения времени измерения БПК₅, начальные данные МТЭ могут быть комбинированы с моделями прогнозирования. Нами было установлено, что кривые напряжения МТЭ могут аппроксимироваться и прогнозироваться функцией плотности вероятности логнормального распределе-

ния с добавленной обратной квадратичной функцией [2], представленной формулой (1):

$$f(x) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} - \frac{a}{b + x^2} \quad (1)$$

В рамках цели текущей работы требовалось применить искусственные нейронные сети для корректировки прогнозов напряжения МТЭ (как следствие биохимического потребления кислорода), полученных с помощью функции (1).

Постановка задачи и формирование DataSet. В работе [5] для прогноза БПК₅ к данным МТЭ применялись нейронные сети, где в качестве входных данных были использованы значения напряжения, измеренные за фиксированное время. Однако, работе [5] нейронная сеть использовалась как основная модель. В отличие от этого, мы предлагаем комбинировать результаты функции (1) и искусственной нейронной сети, что позволит учесть более сложные зависимости и сохранит прозрачность результата.

Мы использовали набор данных, полученный в результате работы [3]. Поскольку в данном наборе содержалось всего 57 кривых напряжения, мы приняли решение использовать их для тестирования, а для обучения же применять кривые, сгенерированные с помощью функции аппроксимации. Данные обучающей выборки были синтезированы с использованием коэффициентов функции (2), представляющей собой комбинацию логнормального и нормального распределения со свободным коэффициентом.

$$f(x) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} + \frac{a}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - b)^2}{2c^2}} + d \quad (2)$$

Данная функция позволяет достичь высокой точности аппроксимации полной экспериментальной кривой напряжения, однако недостаточно гибкая для использования ее при прогнозировании. В процессе синтеза кривых использовался метод случайного варьирования коэффициентов, полученных при аппроксимации экспериментальных данных. Для набора коэффициентов вычислялись стандартные отклонения для каждого значения. На каждом шаге синтеза случайным образом выбирался набор коэффициентов, к которым добавлялся случайный шум. Этот шум генерировался с использованием нормального распределения, где среднее значение равно 0, а стандартное отклонение пропорционально стандартным отклонениям коэффициентов, умноженным на коэффициент 0,1.

Всего для обучающей выборки было синтезировано 2035 кривых напряжения. Данные кривые представляют собой эталон, которые должна предсказать нейронная сеть. После чего для синтезированных кривых были получены коэффициенты функции (1). Коэффициенты были подобраны для участков, начиная от достижения значения в пике, деленного на 1,2, и до момента, когда кривая перестает расти и достигает значения, равного значению в пике, деленному на 1,75, как показано на рис. 1.




Рис. 1. Пример определения участка аппроксимации.

Таким образом, синтезированные кривые использовались на выходе ИНС, а полученные для них результаты аппроксимации и прогноза с помощью функции (1) на входе.

Проектирование и обучение нейронной сети. Искусственная нейронная сеть была создана и обучена с использованием библиотеки `keras` языка `python`. На входе были использованы прогнозные значения кривых напряжения, полученные с помощью функции (1) для синтезированных кривых. Сами синтезированные кривые были использованы на выходе. Кривая состояла из 325 дискретных точек, поэтому количество нейронов на входном и выходном слое ИНС равнялось 325. Также были определены три скрытых слоя с количеством нейронов равным 128, 64, 64 и слой прореживания `Dropout` между вторым и третьим скрытым слоем, с процентом выпадающих нейронов равным 20%. В качестве метода обучения был использован `Adam`, со скоростью обучения 0,001.

Результаты. После обучения нейронная сеть была оценена на тестовой выборке из 57 кривых, то есть только на экспериментальных кривых. Некоторые результаты применения ИНС для прогнозирования кривых напряжения МТЭ приведены на рис. 2.




Рис. 2. Результат применения нейронной сети

Затем к прогнозным значениям напряжения был применен метод определения БПК₅. Средняя относительная ошибка прогнозирования БПК₅ составила 8,15% для среднего входного времени измерения напряжения в 14,2 часа, минимальное время измерения составило 4 часа, а максимальное 24 часа. В то время как нейронная сеть из работы [5] давала погрешность 8,42% для 16 часов измерения и 10,66% для 12 часов.

Заключение. В заключении можно отметить, что внедрение искусственной нейронной сети в процесс прогнозирования параметров микробных топливных элементов существенно расширяет возможности анализа сложных зависимостей, которые могут оставаться незамеченными при использовании традиционных математических моделей. Нейронная сеть служит в данном контексте вспомогательным инструментом, позволяющим улучшить точность и надежность прогнозов без превращения процесса в «черный ящик». Сохраняя результаты функции прогнозирования, мы обеспечиваем прозрачность результатов.

Библиографический список

1. Маслова А., Панарин В., Гришаков К., Рыбка Н., Котова Е., Селезнева Д. Применение искусственных нейронных сетей для прогнозирования уровней загрязнения воздуха и водных объектов. *Экология и промышленность России*. 2019;23(8):36-41. <https://doi.org/10.18412/1816-0395-2019-8-36-41>
2. Корнаухова М.А., Медведев И.А. Математическая модель аппроксимации кривых напряжения микробных топливных элементов // XXVII Региональная конференция молодых ученых и исследователей Волгоградской области: Тезисы докладов, Волгоград, 1 ноября – 15 ноября 2022 года / Редколлегия: А.Э. Калинина (отв. ред.) [и др.]. – Волгоград: Волгоградский государственный университет. – 2023. С. 48–52.
3. G. M. Tardy, B. Lóránt, M. Gyalai-Korpos [et al.]. Microbial fuel cell biosensor for the determination of biochemical oxygen demand of wastewater samples containing readily and slowly biodegradable organics // *Biotechnology letters*. – 2021. Vol. 43. №. 2. P. 445–454. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1007/s10529-020-03050-5>
4. B. Lóránt, M. Gyalai-Korpos, I. Goryanin, G. M. Tardy. Single chamber air–cathode microbial fuel cells as biosensors for determination of biodegradable organics // *Biotechnology letters*. – 2019 Vol. 41. №. 4. P. 555–563. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1007/s10529-019-02668-4>
5. I. Medvedev, M. Kornaukhova, C. Galazis [et al.]. Using AI and BES/MFC to decrease the prediction time of BOD5 measurement. // *Environ Monit Assess*. – 2023. Vol. 195. – P. 1018. [Электронный ресурс]. Режим доступа: <https://doi.org/10.1007/s10661-023-11576-0>

COMBINATION OF A NEURAL NETWORK AND A MATHEMATICAL MODEL FOR PREDICTING THE VOLTAGE OF MICROBIAL FUEL CELLS

Medvedev Ivan Andreevich, Kornaukhova Maria Anatolyevna

Volgograd State University,
400062, Russia, Volgograd, Universitetsky Ave., 100
medvedev2000v@gmail.com, mariya_kornaukhova@volsu.ru

This paper presents the results of combining the results of a mathematical model for predicting the parameters of microbial fuel cells with an artificial neural network. The results obtained allow us to conclude that the working combination allows for more efficient management of complex MFC processes.

Keywords: artificial neural network, microbial fuel cell, biochemical oxygen demand

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ОПРЕДЕЛЕНИЯ ЛЕГИРОВАННОГО СЛОЯ СЕРДЦЕВИНЫ ПРЕФОРМЫ-СТЕРЖНЯ НА ЛИНИИ MCVD ДЛЯ ВЫТЯГИВАНИЯ ОПТОВОЛОКНА

Бахтин Павел Вячеславович, Проскуряков Владислав Сергеевич

Пермский государственный национальный исследовательский университет,
ФИТ. 614068, Россия, г. Пермь, ул. Букирева, 15,
vbahtin2001@gmail.com, izumrudnimidved@gmail.com

В статье представлено описание разработки нейросетевой системы для определения и прогнозирования легированного слоя сердцевины преформы-стержня на линии MCVD для вытягивания оптоволокон. Система позволяет определять легированный слой сердцевины преформы-стержня для дальнейшего изготовления оптоволокон с учетом статистических характеристик кварцевой трубы и регулирования расхода газа.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, оптоволокон, легированный слой, преформа-стержень, распределение расхода газа, кварцевые трубы, осаждение труб, сердцевина.

Введение. Одним из основных этапов изготовления оптоволокон (ОВ) является процесс изготовления заготовок оптических волокон, в который входит изготовление преформ и преформ-стержней.

Для получения ОВ используется метод MCVD (modified chemical vapor deposition – метод внутреннего парофазного осаждения). В опорную кварцевую трубку подают пары четыреххлористого кремния (SiCl_4) и галогенидов легирующих компонентов (GeCl_4 , VBr_3 , POCl_3 и т.д.), а также очищенный и осушенный кислород. В зоне нагрева трубки кислородно-водородной горелкой,

перемещающейся вдоль трубки с заданной скоростью, происходит окисление галогенидов с образованием оксидов кремния и легирующих компонентов.

При изготовлении ОВ очень важно не допустить брака, так как процесс занимает от 8 до 10 часов, важно прогнозировать легированный слой сердцевинны преформы-стержня, который требуется получить. На данный момент существуют только методы, основывающиеся на реальных данных, поэтому для эффективного прогнозирования воспользуемся интеллектуальными системами [1].

Цель данной работы заключается в создании и обучении нейросетевой модели [2], которая позволит прогнозировать диаметр легированного слоя преформ-стержней. Результатом исследования является система прогнозирования легированного слоя сердцевинны преформы-стержня.

Обзор. В результате анализа литературных источников [3-5] был выбран следующий набор показателей: X1 – содержание кремния в рецепте, задаваемое инженером-технологом для линии MCVD, X2 – содержание фосфора в рецепте, задаваемое инженером-технологом для линии MCVD, X3 – содержание бора в рецепте, задаваемое инженером-технологом для линии MCVD, X4 – максимальная диаметр кварцевой трубы, X5 – минимальный диаметр кварцевой трубы, X6 – максимальная толщина стенки, X7 – минимальная толщина стенки, X8 – содержание кремния, измеренное калибровочным устройством при заданном значении подачи газа в 250 мл/мин, X9 – содержание фосфора, измеренное калибровочным устройством при заданном значении подачи газа в 125 мл/мин, X10 – содержание фосфора, измеренное калибровочным устройством при заданном значении подачи газа в 250 мл/мин, X11 – содержание бора, измеренное калибровочным устройством при заданном значении подачи газа в 125 мл/мин, D1 – легированный слой сердцевинны преформы-стержня.

Так как все параметры являются числовыми будем использовать их в начальном виде без кодировки.

Выходной параметр–диаметр легированного слоя сердцевинны преформы-стержня, будем выводить данный параметр в числовом виде.

Множество входных данных о статистических характеристиках кварцевой трубы и регулирования расхода газа основано на реальных данных. 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 35000 примеров. Данное множество было разделено на обучающее и тестирующее в соотношении 90%, 10% соответственно. Собранные данные охватывают период 2021-2023 гг.

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 одиннадцать входных нейронов, один выходной и один скрытый слой с тремя нейронами.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 200 примеров. Средняя

ошибка тестирования составила 10%, что можно считать хорошим результатом. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим и прогнозируемым нейросетью значением легированного слоя сердцевин преформы-стержня случайно отобранных 15 преформ-стержней.

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. 1. Адекватность нейронной сети




Рис. 2. Значимость входных параметров нейросетевой модели

Как видно из рис. 2, наиболее значимыми параметрами являются количество бора в рецепте и количество фосфора в рецепте. Также на графике можно видеть, что остальные параметры имеют около нулевую значимость.

На рис. 3 показан график зависимости значения легированного слоя сердцевин преформы-стержня от количества бора в рецепте. На данном графике можно увидеть прямую зависимость, чем больше значение бора в рецепте, тем больше значение диаметра легированного слоя сердцевин преформы-стержня.

На рис.4 продемонстрирована зависимость процента зависимости значения диаметра легированного слоя сердцевин преформы-стержня от количества фосфора в рецепте. На данном графике можно увидеть обратную зависимость, чем больше значение фосфора в рецепте, тем меньше значение легированного слоя сердцевин преформы-стержня.

На рис. 4 продемонстрирована зависимость процента зависимости значения диаметра легированного слоя сердцевины преформы-стержня от количества фосфора в рецепте. На данном графике можно увидеть обратную зависимость, чем больше значение фосфора в рецепте, тем меньше значение легированного слоя сердцевины преформы-стержня.




Рис. 3. Зависимость значения легированного слоя сердцевины преформы-стержня от количества бора в рецепте




Рис. 4. Зависимость значения легированного слоя сердцевины преформы-стержня от количества фосфора в рецепте

Использование keras. Далее была проведена аналогичная работа с использованием технологии keras и языка программирования Python.

Была создана модель, аналогичная модели в «Нейросимулятор 5».

Опытным путем были подобраны следующие гиперпараметры:

- Активационная функция relu;
- дропаут равен 0.6;
- регуляризация L1 для первого скрытого слоя равна 0.001;
- обучение проходило 500 эпох.

На рис. 5 приведен график обучения данной модели, где синяя линия – это ошибка на обучающем множестве, оранжевая – ошибка на тестирующем.

Далее была проверена адекватность модели. На рис. 6 приведен график сравнения прогнозных и фактических значений.




Рис. 5. Обучение модели с использованием keras и python




Рис. 6. Адекватность нейронной сети

По итогам тестирования среднеквадратичная ошибка составила 8%. Данное значение является схожим с результатом, полученным в «Нейростимулятор 5».

Заключение. Были обучены системы нейросетевого прогнозирования легированного слоя сердцевинны преформы-стержня процесса MCVD. Полученные результаты оказались схожими, но стоит отметить, что работа с «Нейросимулятор 5» проще так для этого не требуются знания в области программирования.

Проведены исследования множества данных обосаждения кварцевой трубы и получении легированного слоя сердцевинны преформы-стержня. Методом сценарного прогнозирования построены графики зависимостей значения легированного слоя сердцевинны преформы-стержня от количества бора в рецепте и количества фосфора в рецепте. Применение такого набора параметров в модели позволяет учитывать внешние факторы с течением времени, а также в дальнейшем она может быть расширена для прогнозирования легированного слоя сердцевинны преформы-стержня для производства ОВ.

Исходя из описанного выше можно сформулировать следующую рекомендацию: наиболее важными показателями являются количество бора и фосфора, подаваемые в результате осаждения кварцевой трубы.

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 //учебное пособие для студентов специальностей 200106 Информационно-измерительная техника и технологии и 230100 Информатика и вычислительная техника / Москва, 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// учебное пособие / Сер. Инновации в образовательных программах национального исследовательского университета. 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.: Издательский центр «Академия», 2005. – 176 с.

NEURAL NETWORK SYSTEM FOR DETERMINING DOPED LAYER OF PREFORM-ROD CORE ON MCVD LINE FOR FIBRE OPTIC PULLING

Bakhtin Pavel V., Proskuriakov Vladislav S.

Perm, State University,
Bukireva str., 15, Perm, Russia, 614068,
vbahntin2001@gmail.com, izumrudnimidved@gmail.com

The article describes the development of a neural network system for determining and predicting the doped layer of the core of a preform rod on the MCVD line for fibre optic drawing. The system allows the determination of the doped layer 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, doped layer, preform-rod, gas flow rate distribution, quartz pipes, pipe deposition, core.

ОПТИМИЗАЦИЯ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ПРОИЗВОДСТВА КАБЕЛЬНОЙ ПРОДУКЦИИ

Азанов Александр Александрович

Хейфец Илья Игоревич

ООО «Камский кабель»

614030, Россия, г. Пермь, Гайвинская улица, дом 105

Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет,

614068, Россия, г. Пермь, ул. Букирева, 15

Национальный исследовательский университет

«Высшая школа экономики»

614070, Россия, г. Пермь, ул. Студенческая, 38

yasn@psu.ru

В статье приведены результаты нейросетевого моделирования и оптимизации технологического процесса производства кабельной продукции на одном из участков завода ООО «Камский кабель».

Ключевые слова: Токопроводящая жила, шаг скрутки, диаметр волокни, алюминий, прогнозирование, оптимизация.

Одним из наиболее ответственных этапов производства кабельно-проводниковой продукции является процесс волочения-скрутки, при котором токопроводящий провод уменьшается в диаметре и скручивается в жилу. Задача технолога состоит в том, чтобы подобрать оптимальные параметры этого процесса, обеспечивающие его потребительские качества при минимальных производственных затратах.

Наша задача состояла в том, чтобы методом нейросетевого моделирования подобрать оптимальное сочетание диаметра волокни и шага скрутки, обеспечивающее минимальную погонную массу токопроводящей жилы при сохранении ее потребительских характеристик.

Задача осложнялась тем, что на заводе имелось всего девять результатов замеров параметров технологического процесса, которые представлены в таблице.

В этой таблице D – диаметр волокни в мм, H – шаг скрутки в мм, M – погонная масса токопроводящей жилы в кг/км. Данные замеры выполнены для провода диаметром 1,79 мм с поперечным сечением 1,79 мм².

Для решения задачи оптимизации технологического процесса на платформе Нейросимулятор-5.0 [1] была спроектирована нейронная сеть слоистой структуры последовательного распространения с двумя входными нейронами, одним выходным нейроном и скрытым слоем из трех нейронов с функциями активации в виде гиперболического тангенса. Валидация и тестирование нейронной сети выполнялось методом Cross-Validation.

Данные замеров параметров технологического процесса

№ за- мера	X1	X2	D1
	<i>D</i> , мм	<i>H</i> , мм	<i>M</i> , кг/км
1	4.6	95	41.225
2	4.62	105	41.53
3	4.62	100	41.653
4	4.62	95	41.633
5	4.62	90	41.621
6	4.62	85	41.65
7	4.58	105	40.91
8	4.58	95	41.03
9	4.58	85	41.11

Не смотря на существенно малый объем Dataset, среднеквадратичная относительная ошибка нейронной сети не превысила 10%, что позволило методом замораживания входных параметров [2] выполнить серию виртуальных компьютерных экспериментов. Результаты экспериментов представлены на рис. 1.




Рис. 1. Нейросетевые прогнозы значений массы токопроводящих жил, получаемых на волокнах различного диаметра с различным шагом скрутки

На рис. 1 маркеры увеличенного размера соответствуют данным заводских значений массы токопроводящих жил таблицы 1. Маркеры меньшего размера соответствуют результатам прогнозов возможных режимов волочения, полученных методом замораживания входных параметров [2].

Из результатов, приведенных на рис.1, видно, что оптимальный режим волочения, при котором достигается минимальная погонная масса токопроводящей жилы, наблюдается при использовании волокни диаметров 4,56 мм и шага скрутки от 95 до 110 мм. Погонная масса токопроводящей жилы при этом достигнет своего минимального значения 40,82 кг/км.

Согласно заводскому акту, экономия алюминия при использовании рекомендованных нейронной сетью параметров составила 1,3%.

Заключение.

1. Предоставленные заводом данные по 9 вариантам режимов волочения и скрутки токопроводящих жил позволили создать нейронную сеть, пригодную для моделирования и решения задачи оптимизации технологического процесса.

2. Анализ полученных нейросетевых прогнозов позволил рекомендовать режим волочения-скрутки с диаметром волокни 4,56 мм и шагом скрутки от 95 до 110 мм. Прогнозная минимальная масса токопроводящей жилы при этом составила 40.82 кг/км. При использовании на заводе рекомендованных нейронной сетью параметров была зафиксирована экономия алюминия 1,3%.

3. В выполненных компьютерных экспериментах виртуальному изменению подвергались только два входных параметра нейронной сети: диаметр волокни и шаг скрутки. Более качественные рекомендации по оптимизации технологических процессов завода могут быть получены в ходе дальнейших вычислительных экспериментов при использовании более широкого круга входных параметров, таких как диаметр провода и площадь его поперечного сечения и др.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
2. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
<https://cloud.mail.ru/public/5H3z/4LxCpIsxw>

OPTIMIZATION OF THE TECHNOLOGICAL PROCESS OF CABLE PRODUCTS PRODUCTION

Alexander A. Azanov

Ilya I. Kheifets

Perm State National Research University

Bukireva str., 15, Perm, Russia, 614068

ООО «Kamsky Kabel»

614030, Russia, Perm, Gayvinskaya Street, Building 105

Leonid N. Yasnitsky

Perm State National Research University

Bukireva str., 15, Perm, Russia, 614068 HSE University,

Str. Studencheskaya, 38, Perm, Russia, 614070

yasn@psu.ru

The article presents the results of neural network modeling and optimization of the technological process of cable products production at one of the sites of the Kamsky Kabel LLC plant.

Keywords: Conductor, twist pitch, die diameter, aluminum, forecasting, optimization.

МЕТОДОЛОГИЧЕСКИЙ ПОДХОД К ФОРМИРОВАНИЮ ЦИФРОВОГО ПРЕДСТАВЛЕНИЯ ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ В ГОРОДЕ ПЕРМИ

Ташкинов Алексей Григорьевич

Пермский национальный исследовательский политехнический университет,
614068, Россия, г. Пермь, ул. Комсомольский проспект, 29
АО «Пермский завод «Машиностроитель»
614014, Россия, Пермь, ул. Новозвягинская, 57
a-tashkinov@pzmash.perm.ru

Аннотация. В статье представлено описание методологического подхода на базе цифровых инструментов с использованием искусственного интеллекта, машинного обучения для формирования цифрового представления существующих промышленных предприятий в городе Перми. Представлен анализ отличительных особенностей – традиционных от цифровых предприятий. Предложенный подход позволяет руководителям предприятий осуществлять эффективную работу предприятия в условиях цифровой трансформации.

Ключевые слова: искусственный интеллект, цифровые и киберфизические предприятия, подход, цифровые технологии.

Введение. Правительством РФ в 2023 году утверждена Концепция технологического развития, определяющая содержание и направления обеспечения технологического развития на период до 2030 года, а также соответствующие проекты с применением новых, сквозных технологий и искусственного интеллекта [1].

Благодаря динамичному развитию больших данных, промышленного интернета вещей, искусственного интеллекта, машинного обучения, цифровых двойников и облачных вычислений и др. цифровых технологий, – цифровая экономика меняет краткосрочные на долгосрочные ориентиры и становится для предприятий новым двигателем для достижения эффективного развития производственно-экономической системы. Трансформация цифровой экономики предполагает процесс перехода от традиционных бизнес-моделей к новым моделям, основанным на использовании информационно-коммуникационных технологий с целью адаптации к изменяющимся рыночным условиям и требованиям потребителей. Использование цифровых инструментов таких как, искусственный интеллект, машинное обучение, блокчейн, интернет вещей, позволяет компаниям автоматизировать решение текущих задач и улучшить взаимодействие, как с клиентами, так и между отделами внутри организации [2].

Анализ практики создания цифрового представления существующих промышленных предприятий позволяет сделать следующие выводы [3]:

Сегодня нет бизнеса, не затронутого цифровой трансформацией, и нет вида работы, который не был бы изменен, пусть и незначительно, цифровыми инструментами;

Технических навыков и глубокого интереса к новым технологиям недостаточно для процветания в цифровой экономике;

Цифровые технологии постоянно меняются, меняются и способы их применения.

Это означает, что организации и люди в них находятся в состоянии постоянных изменений;

В век данных, алгоритмов и искусственного интеллекта, невозможным добиться успеха без цифрового мышления, позволяющего по-новому взглянуть на мир и изменить свое поведение.

Цифровое мышление – это набор подходов, которые мы используем для осмысления и использования данных и технологий.

В этой связи актуальной является задача по созданию такого цифрового представления сложного технического объекта, которое базируется на рассмотрении искусственного интеллекта, как многофункциональной системы.

В настоящее время развитие современных цифровых инструментов с использованием искусственного интеллекта, машинного обучения и нейросети, ориентированные на цифровое представление объекта позволяют решить перечисленные проблемы. Целью настоящего исследования является представление подходов на базе цифровых инструментов с использованием искусственного интеллекта, машинного обучения для формирования цифрового представления существующих промышленных предприятий в городе Перми.

Отличительные особенности анализируемых предприятий – традиционных от цифровых предприятий. На основе рассмотренных работ представим анализ отличительных особенностей существующих предприятий, исследуемых в нашей работе [4-10]:

Традиционные, цифровые и киберфизические предприятия существенно различаются по ряду параметров:

Во-первых, по способу взаимодействия людей: если традиционные предприятия требуют от сотрудников сосредоточиться на обсуждении и принятии решений в физических конференц-залах, то цифровые предприятия позволяют взаимодействовать без границ, при этом сотрудничество, встречи и обмен данными внутри и между предприятиями происходят в любое время и в любом месте. Этот сдвиг в модели сотрудничества – главное отличие цифрового предприятия от традиционного. Киберфизическое предприятие, с другой стороны, сочетает в себе эти два направления, используя цифровые технологии для эффективного сотрудничества, но при этом учитывая практические ограничения и условия физического мира;

Во-вторых, с точки зрения менталитета, цифровые предприятия используют данные + алгоритмические стратегии, чтобы справиться с неопределенностью и обеспечить управление, в то время как традиционные предприятия могут больше полагаться на опыт и интуицию при принятии решений. Киберфизические предприятия, с другой стороны, должны дополнительно учитывать правила и ограничения физического мира на основе цифрового мышления.

Кроме того, с точки зрения методов производства, цифровые предприятия используют цифровые технологии для достижения взаимосвязи производствен-

ных факторов предприятия и способны гибко корректировать производственные стратегии в соответствии с изменениями на рынке. Традиционные предприятия, с другой стороны, могут использовать крупномасштабные методы серийного производства. Киберфизические предприятия должны учитывать реальные производственные возможности и ограничения физического мира на основе цифрового производства. Как цифровые, так и киберфизические предприятия должны учитывать особенности цифровой трансформации, которая осуществляется в рамках концепции Индустрия 4.0 и формирования концепции Индустрия 5.0.

Что касается работы, то цифровые предприятия реализуют модель совместного управления, которая является стандартизированной, регулируемой, плоской, онлайн и эффективной, а также устанавливают систему управления, ориентированную на людей. Традиционные предприятия могут использовать более громоздкий иерархический подход к управлению. Киберфизическим предприятиям необходимо анализировать вопросы о том, как добиться эффективного функционирования и управления физическим миром на основе цифрового управления.

Традиционные предприятия обычно имеют фиксированную бизнес-модель, полагаясь в основном на офлайн-рынки для продаж и на традиционные каналы рекламы, продвижения и дистрибуции для продвижения своих продуктов, и услуг. Кроме того, традиционные предприятия склонны применять более традиционный подход к управлению цепочками поставок и производственными процессами, а также не обладают эффективными возможностями обмена информацией и сотрудничества. Бизнес-модель цифровых предприятий, напротив, в большей степени ориентирована на принятие решений на основе данных и расширение рынка в режиме онлайн. Они в полной мере используют большие данные, облачные вычисления, искусственный интеллект и другие цифровые технологии для сбора и анализа больших объемов пользовательских данных, чтобы получить представление о тенденциях рынка и потребностях клиентов. Бизнес-модель киберфизических предприятий, с другой стороны, подчеркивает глубокую интеграцию физического и цифрового миров. Они соединяют производственное оборудование, датчики и системы управления с помощью технологии IoT, чтобы обеспечить мониторинг, сбор данных и интеллектуальный анализ производственного процесса в режиме реального времени. Киберфизические предприятия используют эти данные для оптимизации производственных процессов, повышения производительности и создания индивидуальных продуктов. Традиционные предприятия имеют относительно низкий уровень развития технологий. Они обычно полагаются на традиционные технологии и инструменты для производства и работы и медленно принимают, и применяют новые технологии.

С учетом проведенного анализа можно сделать вывод, что традиционные, цифровые и киберфизические предприятия существенно различаются по способам взаимодействия, мышления, производства, работы и принятия решений. Эти различия отражают разные стратегии и ориентации разных предприятий в

решении задач интеллектуализации производственных систем и цифровой трансформации.

Развитие технологий искусственного интеллекта (далее – ИИ) в части, касающейся автоматизированных систем, заслуживает особого подхода. Это обусловлено целым рядом причин [11]:

Во-первых, в автоматизированных системах в силу включенности в их процессы человека одной из главных задач является обработка неструктурированных текстовых данных на естественном языке.

Во-вторых, направление обработки естественного языка среди других технологий ИИ сталкивается с наибольшим количеством проблем (особенно при выявлении смысла текста) и находится на сравнительно низком уровне технологической готовности.

В-третьих, именно проблемы, порождаемые задачами смысловой обработки естественного языка, приводят все большее число исследователей к выводу о целесообразности совместного применения нейросетевого ИИ и так называемого логического ИИ, а также о том, что такое совмещение может привести к созданию универсального (сильного) искусственного интеллекта, способного рассуждать, автономно извлекать знания из книг и других документов, решать неизвестные ранее задачи.

Последнее обстоятельство, по нашему мнению, создает предпосылки для получения эффективных решений, но одновременно и понимание тех рисков, которые возникают в случае, если результаты такого совмещения логического и нейросетевого ИИ будут получены не в России, а, допустим, в других странах – участницах работ по созданию сильного ИИ (Artificial General Intelligence – AGI) [12].

Исследования последних лет дают все больше оснований для того, чтобы предполагать создание в ближайшее десятилетие универсально (сильного) ИИ. В первую очередь такой оптимизм обусловлен теми результатами, которые демонстрируют так называемые базисные предобученные нейросетевые модели (foundation models). Как известно, базисные нейросетевые модели, в основном типа трансформеров, прошедшие предварительное обучение (без учителя) на больших объемах (терабайтах) текстовых данных и насчитывающие сотни миллиардов – триллионы параметров, способны быстро дообучаться (с учителем) применительно к узкоспециализированным предметным областям по относительно небольшим обучающим выборкам.

Подход к цифровому представлению предприятия в процессе реализации проекта цифровой трансформации АО «Пермский завод «Машиностроитель». Далее рассмотрим внедрение внутренней конференции связи – ВКС. ВКС в системе корпоративных коммуникаций. АО «Пермский завод «Машиностроитель» (АО «ПЗ «Маш») – крупное специализированное машиностроительное предприятие. АО «ПЗ «Маш» входит в состав военно-промышленной корпорации «НПО машиностроения» в составе которого в 2012г. вошло в Корпорацию «Тактическое ракетное вооружение».

Предпосылки и условия создания на АО «ПЗ «Маш» полнофункциональной отечественной системы корпоративных коммуникаций включают в себя

две группы предпосылок: объективно-исторические и организационно-технические [9, 10].

АО «ПЗ «Маш» построена на основе технологий TrueConf. Почему мы говорим на основе технологий TrueConf, потому что на основе разработанных специалистами ИТ-службы АО «ПЗ «Маш» технических требований и технического задания разработчиками TrueConf и «Академии бизнес решений» выполнена глубокая интеграция систем IP-телефонии и видеоконференцсвязи, что позволили говорить о создании системы объединенных коммуникаций – с едиными справочниками абонентов, отслеживанием статуса присутствия, реализации различных IVR-сценариев взаимодействия персонала и производственных информационных систем посредством коммуникационных сервисов.

Таким образом, в процессе реализации проекта цифровой трансформации была создана единая коммуникационная система с предварительным названием «СИРИУС» – Синергично Интегрированная Речевая Информационно-Управляющая Система. Результатом является реализация интеллектуальных сценариев информационного обмена «человек – ИС»; «ИС – ИС» на базе модуля искусственного интеллекта с распознаванием и синтезом речи «СИРИУС, «Речевые технологии».

Заключение. Цифровизация производства ведет к повышению интенсивности и плотности информационных потоков. Это может приводить к снижению производительности, а не к повышению как ожидается. Платформа корпоративных коммуникаций должна обеспечивать взаимодействие людей и систем на человеческом языке и стать посредником, ускоряющим обработку лавинообразного потока информации. Предложение видеоконференцсвязи – нужны коммуникационные сервисы для всех предприятий города Перми. Это поможет в наращивании горизонтальных связей, в том числе, например, в рамках центров компетенций.

Таким образом, рассмотренный нами в работе методологический подход позволяет руководителям предприятий города Перми осуществлять эффективную работу предприятия в условиях цифровой трансформации.

Библиографический список

1. Национальный портал в сфере ИИ и применения нейросетей в России: официальный сайт [Электронный ресурс] URL: <https://ai.gov.ru/>. (дата обращения 30.07.2024)
2. Ташкинов А.Г. Методика оценки эффективности проектов цифровой трансформации предприятия / сборник трудов Международной научно-практической конференции, Интеллектуальная инженерная экономика и Индустрия 5.0 (ИНПРОМ) 25–28 апреля 2024г. В 2 т. Т.2/ под ред. д-ра экон. наук, проф. Д. Г. Родионова, д-ра экон. наук, проф. А. В. Бабкина. – СПб.: ПОЛИТЕХ-ПРЕСС, 2024. С. 502–507.
3. Чернова О.А., Даренин А.И. Цифровые трансформации в промышленности как фактор экономического роста //Естественно-гуманитарные исследования. – 2020. – №. 1 (27). – С. 222-226.
4. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
5. Шнайдер, О'Гордон, Хуа Цянсен, Стратегическое мышление о цифровой трансформации традиционных предприятий, Шанхайские государственные активы, том 3, № 74-75, 2016, стр. 2. [Электронный ресурс] URL https://lib.cqvip.com/Qikan/Article/Detail?id=668378930&from=Qikan_Article_Подробнее

6. Бабкин А.В., Дин Хайци Традиционные, цифровые и киберфизические предприятия: понятие, сущность и особенности / сборник трудов Международной научно-практической конференции, Интеллектуальная инженерная экономика и Индустрия 5.0 (ИНПРОМ) 25–28 апреля 2024г. В 2 т. Т.2/ под ред. д-ра экон. наук, проф. Д. Г. Родионова, д-ра экон. наук, проф. А. В. Бабкина. – СПб.: ПОЛИТЕХ-ПРЕСС, 2024. С. 156 – 160.

8. Babkin A., Shkarupeta E., Kabasheva I., Rudaleva I., Vicentiy A. A Framework for Digital Development of Industrial Systems in the Strategic Drift to Industry 5.0. International Journal of Technology 13(7) 174-182 (2022). <http://doi.org/10.14716/ijtech.v13i7.6193>

9. Фофанов О.Г. Разработка и внедрение российской системы объединенных коммуникаций / Сборник докладов форума по цифровизации оборонно-промышленного комплекса России, XI Форум ИТОПК. М.: Connect, 2022. С.101 – 102.

10. Ташкинов А.Г. Повышение операционной эффективности АО «Пермский завод «Машиностроитель» при реализации проектов цифровой трансформации предприятия. Управление качеством. – 2024, №7, С. 21 – 29.

11. Протасов А.А., Ширманов А.В., Родоманов С.И. Современные задачи автоматизации органов военного управления на базе технологий искусственного интеллекта // Военная мысль. 2022. № 4. С. 79 – 87.

12. Протасов А.А., Ширманов А.В., Родоманов С.И. Перспективы развития искусственного интеллекта и задачи разработчиков оборонно-промышленного комплекса в контексте автоматизации деятельности органов военного управления // Сборник докладов X форума по цифровизации оборонно-промышленного комплекса России, ИТОПК. М.: Connect, 2021. С.147 – 149.

METHODOLOGICAL APPROACH TO THE FORMATION OF DIGITAL REPRESENTATION OF INDUSTRIAL ENTERPRISES IN THE CITY OF PERM

Tashkinov Aleksey Grigorievich

Perm National Research Polytechnic University,
614068, Russia, Perm, Komsomolsky Prospekt St., 29
JSC Perm Plant Mashinostroitel
614014, Russia, Perm, Novozvyaginskaya St., 57

The article presents a description of the methodological approach based on digital tools using artificial intelligence, machine learning to form a digital representation of existing industrial enterprises in the city of Perm. An analysis of the distinctive features of traditional from digital enterprises is presented. The proposed approach allows enterprise managers to effectively operate the enterprise in the context of digital transformation.

Keywords: artificial intelligence, digital and cyber-physical enterprises, approach, digital technologies.

Секция: Искусственный интеллект, медицина и здравоохранение

УДК 004.032.26

СУЩНОСТЬ ПРИМЕНЕНИЯ LLM МОДЕЛЕЙ В СФЕРЕ ЗДРАВООХРАНЕНИЯ

Назаров Дмитрий Михайлович

Уральский государственный экономический университет,
620144, г. Екатеринбург, ул. 8 Марта/Народной Воли, д. 62/45;
Пермский государственный национальный исследовательский университет,
614068, Россия, г. Пермь, ул. Букирева, 15
slup2005@mail.ru

Бадаев Феликс Иосифович

Уральский государственный экономический университет,
620144, г. Екатеринбург, ул. 8 Марта/Народной Воли, д. 62/45
bfi52@mail.ru

В статье рассмотрены возможности применения больших языковых моделей (LLM) в здравоохранении для автоматизации обработки медицинской информации и поддержки клинических решений. Приведены примеры возможностей использования моделей, таких как BioBERT, PubMedBERT, GigaChat и Yandex GPT. Особое внимание уделено принципам и сущности работы моделей.

Ключевые слова: большие языковые модели (LLM-модели), здравоохранение, автоматизация, искусственный интеллект.

Введение. Цифровая трансформация затрагивает все большее количество сфер деятельности человека. Модели машинного обучения и интеллектуальный анализ данных с каждым годом становится точнее и начинает применяться в таких чувствительных областях как медицина. Большие языковые модели (БЯМ, LLM) являются одним из трендов развития искусственного интеллекта последних 3 лет, их применение в сфере здравоохранения становится все более актуальным. В сфере здравоохранения ежедневно генерируется огромное количество информации, начиная от электронных медицинских записей и заканчивая результатами исследований и клиническими рекомендациями конкретным пациентам. Обработка и анализ этих данных требуют значительных усилий и времени от медицинского персонала разного уровня. LLM модели, такие как GPT (GenerativePre-trainedTransformer), предлагают инновационные решения для автоматизации и оптимизации этих процессов в контексте стремительного развития технологий искусственного интеллекта.

В настоящее время исследования такого рода в России являются скорее исключением, чем общепринятой практикой и это связано с тем, что подавля-

ющее большинство медицинских работников не знакомы с возможностями больших языковых моделей, не имеют доступа к специализированным медицинским сервисам, которые позволяют проводить интеллектуальную обработку данных медицинских исследований, а также не имеют соответствующих компетенций для эффективной работы с этими сервисами.

Цель статьи разработать принципы применения LLM-моделей в сфере здравоохранения.

Роль LLM моделей в медицинской практике. Применение больших языковых моделей (LLM) в здравоохранении активно исследуется и развивается, что подтверждается многочисленными научными работами и разработками. Ниже представлен обзор ключевых исследований и технологий, демонстрирующих потенциал и реальные примеры использования LLM моделей в медицинской практике.

Таблица 1

Роль LLM моделей в медицинской практике

Модель	Компания	Возможности	Роль в медицинской практике
BioBERT	Korea University & Clova AI, 2019	1. Идентификация медицинских сущностей. 2. Классификация клинических документов- 3. Анализ биомедицинских текстов	1. Анализ научных публикаций и исследований 2. Поддержка клинических исследований и разработок. 3. Автоматизация обработки медицинской информации
PubMedBERT	Allen Institute for AI, 2020	1. Анализ и обобщение научных статей- 2. Обработка данных из PubMed 3. Извлечение информации (инсайтов) из научных публикаций	1. Поддержка медицинских исследований. 2. Быстрое извлечение и обобщение научной информации. 3. Поддержка врачей и ученых в доступе к актуальной научной информации мирового уровня
GigaChat	Сбербанк, 2022	1. Обработка русскоязычных текстов. 2. Генерация ответов на вопросы медицинской тематики в том числе 3. Автоматизация административных задач	1. Автоматизация обработки медицинской документации в русскоязычных странах. 2. Поддержка пациентов с использованием чат-ботов. 3. Обучение медицинского персонала на русском языке
Yandex GPT	Яндекс, 2022	1. Генерация ответов на вопросы на русском языке. 2. Обработка больших объемов данных. 3. Автоматизация административных процессов	1. Поддержка пациентов с помощью русскоязычных автоматизированных сервисов. 2. Автоматизация обработки и анализа медицинской информации. 3. Помощь врачам в доступе к справочной информации на русском языке

Как показывает анализ, проведенный в таблице 1 начиная с 2019 года интерес со стороны медицинского сообщества к большим языковым моделям, постоянно растет, а сами модели с каждым годом демонстрируют увеличивающийся в геометрической прогрессии спектр возможностей, от генерации отве-

тов на вопросы и анализа медицинских текстов до автоматизации административных задач и поддержки клинических решений.

Сущность и принципы работы LLM-моделей. Принципы работы GPT моделей в процессе анализа и генерации текстов основаны на использовании двух важнейших компонент: архитектуры трансформеров и механизма внимания. Рассмотрим, как GPT-модель генерирует ответ на вопрос (вместо врача), основанный на результатах медицинской диагностики пациента.

Запрос. Пациентка 45 лет поступила с жалобами на усталость, потерю веса и ночную потливость. В анамнезе – гипертензия и диабет 2 типа. Результаты лабораторных исследований показывают повышение уровня лимфоцитов и С-реактивного белка. Какие возможные диагнозы можно поставить пациентке и какие дополнительные исследования следует провести для уточнения предполагаемых диагнозов?

После получения запроса LLM-модель начинает действовать по определенному алгоритму.

Шаг 1. Токенизация запроса. Модель разбивает запрос на токены (числовые представления слов и символов) и анализирует их с помощью встроенного в нее механизма внимания. Например, в нашем запросе токенами могут быть: "пациентка", "45 лет", "поступила", "с жалобами", "на усталость" и др.

Шаг 2. Анализ запроса. Механизм внимания (attention mechanism) – это ключевой компонент архитектуры трансформеров, который позволяет моделям обрабатывать и генерировать текст в соответствии с запросом. Механизм внимания оценивает **важность** каждого слова входной последовательности (запроса) относительно других слов и определяет их вклад (вес) в генерацию каждого элемента выходной последовательности. Чтобы понять, как это делает модель рассмотрим основные элементы механизма внимания на примере токена «усталость». Для токена «усталость» вычисляются запросы (Q), ключи (K) и значения (V).

- Запрос (Q) формализует ответ на вопрос: как важен токен «усталость» для поиска ответа на вопрос?

- Ключи (K) вычисляются исходя из определения важности других токенов относительно токенам «усталость». То есть происходят следующие числовые оценки. У нас числа будут заменены на слова естественного языка (низкий, средний высокий).

«Пациентка»: важность в контексте токена «усталость» (может быть низкой).

«45 лет»: важность в контексте токена «усталость» (может быть средней).

«с жалобами»: важность в контексте токена «усталость» (может быть высокой).

«на усталость»: важность в контексте токена «усталость» (очень высокая, так как это сам токен).

- Значения (V), по сути определяют смысловую нагрузку каждого токена.

Пример ответа.

«Пациентка»: информация о пациенте (женщина, 45 лет).

«45 лет»: возраст пациента.

«поступила»: информация о обращении пациента за медицинской помощью.

«с жалобами»: информация о конкретных жалобах пациента.

«на усталость»: конкретная жалоба пациента (усталость).

Используя механизм внимания, модель определяет, какие токены (ключи) наиболее важны для текущего токена (токена из запросаQ) и вычисляет их вклад в формирование ответа. Это позволяет модели учитывать более важные токены, как более релевантные части текста при формировании окончательного ответа.

Шаг 3. Генерация гипотез.

Используя знания, накопленные в процессе обучения (на основе огромного массива исторических данных), GPT-модели генерируют возможные гипотезы относительно диагноза пациента. В данном случае модель может рассмотреть такие варианты, как лимфома, инфекция, аутоиммунное заболевание или осложнение уже имеющегося заболевания «диабет».

Шаг 4. Формулировка ответа.

Модель в итоге формулирует ответ, объединяя сгенерированные гипотезы и рекомендации. Ответ представлен в ясной и структурированной форме, чтобы медицинский работник мог легко интерпретировать и использовать эту информацию при определении диагноза.

Ответ: «Пациентка 45 лет с жалобами на усталость, потерю веса и ночную потливость, в анамнезе – гипертензия и диабет 2 типа, повышение уровня лимфоцитов и С-реактивного белка. Возможные диагнозы включают лимфому, инфекцию (например, туберкулез), аутоиммунное заболевание (например, системную красную волчанку) или осложнение диабета. Рекомендуется провести биопсию лимфатического узла, КТ грудной клетки и дополнительные серологические тесты для уточнения диагноза».

Заключение. В заключение следует отметить, что большие языковые модели (LLM) представляют собой важное направление развития технологий искусственного интеллекта в сфере здравоохранения, которое открывает новые возможности для проведения интеллектуального анализа и обработки медицинских данных, включая постановку первичного диагноза. Применение LLM-моделей в массовой медицинской практике позволит сократить время на выполнение рутинных задач медицинскому персоналу и повысить вариативность при определении окончательного диагноза пациенту. При этом однако необходимо понимать, что для широкого внедрения этих технологий в медицинскую практику необходима специализированная подготовка медицинского персонала для того, чтобы они могли правильно использовать потенциал LLM-моделей в своей работе. Важно развивать компетенции медицинских работников в области автоматизации работы с медицинскими данными с помощью искусственного интеллекта. Таким образом, LLM модели имеют большой потенциал для улучшения качества медицинского обслуживания, если их применение будет осуществляться с учетом понимания сущности и принципов работы этих моделей.

Библиографический список

1. Mehandru, N., Miao, B., Almaraz, E., Sushil, M., Butte, A., & Alaa, A. (2023). Large Language Models as Agents in the Clinic. ArXiv, abs/2309.10895. <https://doi.org/10.48550/arXiv.2309.10895>.
2. Wang, G., Yang, G., Du, Z., Fan, L., & Li, X. (2023). ClinicalGPT: Large Language Models Finetuned with Diverse Medical Data and Comprehensive Evaluation. ArXiv, abs/2306.09968. <https://doi.org/10.48550/arXiv.2306.09968>.
3. Sharaf, S., & Anoop, V. (2023). An Analysis on Large Language Models in Healthcare: A Case Study of BioBERT. ArXiv, abs/2310.07282. <https://doi.org/10.48550/arXiv.2310.07282>.
4. Назаров Д. М., Бегичева С. В. Применение больших языковых моделей в образовательном процессе // Бизнес. Образование. Право. 2024. № 3(68). С. 430–436. DOI: 10.25683/VOLBI.2024.68.1057.

THE ESSENCE OF APPLICATION OF LLM MODELS IN HEALTHCARE

Nazarov Dmitry M.

Ural State University of Economics,
620144, Yekaterinburg, ul. 8 Marta/NarodnoyVoli, 62/45;
Perm State National Research University,
614068, Russia, Perm, ul. Bukireva, 15
slup2005@mail.ru

Badaev Felix I.

Ural State University of Economics,
620144, Yekaterinburg, ul. 8 Marta/NarodnoyVoli, 62/45
bfi52@mail.ru

The article considers the possibilities of using large language models (LLM) in healthcare for automation of medical information processing and support of clinical decisions. Examples of the possibilities of using models such as BioBERT, PubMedBERT, GigaChat and Yandex GPT are given. Particular attention is paid to the principles and essence of the models.

Keywords: large language models (LLM models), healthcare, automation, artificial intelligence.

МЕТОД ФОРМИРОВАНИЯ ДЕСКРИПТОРОВ ДЛЯ КЛАССИФИКАТОРОВ МЫШЕЧНОЙ УСТАЛОСТИ, ОСНОВАННЫЙ НА ВЕЙВЛЕТ-АНАЛИЗЕ СЕГМЕНТОВ ЭЛЕКТРОМИОСИГНАЛА

Петрунина Елена Валерьевна

Московский политехнический университет,
107023, Россия, г. Москва, ул. Большая Семёновская д. 38
ekaterinazyankina@gmail.com

Пшеничный Александр Евгеньевич

Юго-Западный государственный университет,
30500, Россия, г. Курск, ул. 50 лет Октября, 94
SFilist@gmail.com

Ермаков Дмитрий Андреевич

Юго-Западный государственный университет,
30500, Россия, г. Курск, ул. 50 лет Октября, 94
dmitriyermakov98@yandex.ru

В статье представлено описание методов формирования дескрипторов для классификаторов степени мышечной усталости в многоагентных гибридных систем машинного обучения. Дескрипторы вычисляются путем анализа эволюции вейвлет-плоскости сегментов электромиограммы в процессе выполнения тестовой нагрузки. Предложен способ получения шкалы мышечной усталости, позволяющий учитывать физические возможности пациента при формировании обучающих выборок для системы машинного обучения.

Ключевые слова: поверхностная электромиография, мышечная усталость, обработка биомедицинских сигналов, вейвлет-анализ, дескрипторы, нейронные сети.

Введение. Мышечная усталость (МУ) определяется как «неспособность поддерживать требуемую или ожидаемую силу». Это сложное явление, наблюдаемое в повседневной жизни, которое вызвало большой интерес в областях спорта, медицины, робототехники и эргономики. Для многих пациентов с нервно-мышечными нарушениями учет МУ имеет решающее значение при разработке эффективных программ реабилитации, а оценка усталости может предоставить важную информацию о функции скелетных мышц, а также необходимость ассистирующих моментов в промышленных и медицинских экзоскелетов. Систематический подход к оценке МУ может дать важные сведения о самой инвалидности, о ее прогрессировании и об эффективности применяемых методов лечения [1].

В настоящее время используемые в клинической практике методы определения МУ оценивают ее с помощью качественных оценочных шкал. Поверхностная электромиография (пЭМГ) является неинвазивным и широко используемым методом оценки МУ и определенные характеристики сигнала пЭМГ могут быть индикаторами МУ. Учитывая различные уровни эффективности методов оценки МУ, используемых в настоящее время в клинической практике,

необходимы исследования, направленные на разработку надежных и объективных инструментов оценки МУ [1].

Анализ методов – аналогов. Известен метод оценки МУ на основе двухканальной пЭМГ, получаемой с мышц-синергистов, принимающих участие в выполнении физической тестовой нагрузки [2, 3]. Сущность метода состоит в том, что паттерны мышечной синергии формируются посредством образования в каждом канале пЭМГ частотного и амплитудного подканалов и определения показателя корреляции сигналов в частотных подканалах всех каналов пЭМГ и показателя корреляции сигналов в амплитудных подканалах всех каналов пЭМГ. В двух каналах получаем показатели синхронности Z1 и Z2, которые являются лингвистическими переменными и описываются тремя термами паттернов синергии: L, M и H, что соответствует низкому, среднему и высокому уровням корреляции синергистов. Классификацией полученных показателей синхронности осуществляется посредством нечеткого логического вывода. При наличии трех термов и двух лингвистических переменных консеквенты в решающих правилах формируются посредством таблицы, строки и столбцы которой соответствуют используемым термам, а в ячейках таблицы записывается терм выходной лингвистической переменной Z, в частном случае, у которой тоже может быть три терма.

Структурная схема для реализации этого способа представлена на рис. 1. Она включает два миоэлектронных устройства считывания (МЭУС) 1 и 2, по одному на каждый канал пЭМГ, и блок нечеткого логического вывода (БНЛВ) 3. БНЛВ включает блок корреляционных детекторов (БКД) 4, блок фуззификаторов 5, на выходе которого формируются нечеткие логические переменные Z1 и Z2, базу нечетких решающих правил 6 и дефуззификатор 7, на выходе которого формируется показатель оценки мышечной усталости Z.

БКД включает два умножителя 8 и 9 и два фильтра скользящего среднего (ФСС) 10 и 11. На выходе БКД формируются два паттерна сигналов синергии

$$y_1[t_n] = \frac{1}{N} \sum_{i=n}^{n+N-1} x_{a1}[t_i] \cdot x_{a2}[t_i], \quad (1)$$

$$y_2[t_n] = \frac{1}{N} \sum_{i=n}^{n+N-1} x_{u1}[t_i] \cdot x_{u2}[t_i], \quad (2)$$

где N – ширина окна ФСС 10 и 11, n – текущий отсчет времени, i – апостериорные отсчеты времени, $x_{a1}[t_i]$ и $x_{a2}[t_i]$ – цифровые сигналы с подканалов амплитудных детекторов МЭУС 1 и 2, $x_{u1}[t_i]$ и $x_{u2}[t_i]$ – цифровые сигналы с подканалов частотных детекторов МЭУС 1 и 2.

Для формирования дескрипторов Z1 и Z2, а также для формирования базы нечетких импликаций в процессе осуществления способа экспериментальным путем определяют соответствие между приложенной нагрузкой на мышцы синергисты и параметрами пЭМГ. Это позволит формировать функции принадлежности и нечеткие решающие правила для БНЛВ.




Рис. 1. Структурная схема устройства оценки мышечной усталости на основе двухканальной электромиограммы, получаемой с мышц-синергистов

Однако такой способ контроля МУ имеет ряд недостатков, основной из которых связан с тем, что при моделировании МУ путем воздействия физической нагрузки на мышцы, не учитываются индивидуальные физические возможности организма человека, так как одна и та же нагрузка будет вызывать различный уровень усталости у различных индивидуумов, что приводит к трудностям формирования правил нечеткой продукции и неточности их решений. Кроме того, анализ МУ на основе анализа пЭМГ, снимаемым с двух мышц, не совсем удобен при электростимуляции, так как стимулирующие воздействия направлены на одну мышцу.

Всвязисэтимв [4] было предложено при формировании дескрипторов для классификатора МУ использовать эволюцию показателей одноканальной пЭМГ. Алгоритм реализации этого способа включает следующие процедуры:

1. Сбора данных (запись одноканальной пЭМГ с соответствующей мышцы).
2. Вычисление непрерывного вейвлет-преобразования (CWT) электромиосигнала каждые 25 секунд. Расчет CWT каждые 25 секунд предлагается для удовлетворения минимальных требований к количеству данных, с которыми можно работать, и медицинских требований, которые защищают здоровье пациента.

3. Расчет общей энтропии вейвлета (TWE) для вейвлет-коэффициентов на каждом интервале. TWE основан на принципе энтропии Шеннона, определяемой как

$$S_{wt} = -\sum [p_i \ln p_i], \quad (3)$$

где p_i – распределение вероятностей или относительная энергия вейвлета (RWE) в заданном масштабе:

$$RWE_i = \sum_k CWT_{i,k}^2, \quad (4)$$

где k – номер отсчета вейвлет-коэффициента на масштабе с номером i .

Для количественной оценки приращения энергии была выбранаобщая (глобальная) энтропия вейвлета (TWE), поскольку она показала лучшие результаты, чем другие классификаторы энергии вейвлета. TWE определяется как:

$$TWE = \frac{S_{wt}}{N}, \quad (5)$$

где N – максимальный масштаб, используемый в вейвлет-анализе.

4. Расчет процента роста TWE в интервалах по 25 секунд (по отношению к первым 25 секундам). Уровни МУ определяются на основе процентного роста TWE : рост 1%-136% – первый уровень утомления, рост 137%-199% – второй уровень утомления, рост 200%-280% третий уровень утомления, выше 281% – четвертый уровень утомления. Этот алгоритм был использован для биоуправления электростимуляцией мышц в биотехнических системах реабилитационного типа, например, электростимуляция должна быть остановлена на уровне МУ равного двум.

Метод формирования дескрипторов по результатам вейвлет -анализа электромиосигнала. Идея метода состоит в получении CWT сегмента пЭМГ, который во временном интервале соответствует двигательной активности исследуемой мышцы. На рис. 2а показан сигнал пЭМГ мышцы, выполняющей периодическую тестовую нагрузку. Интервал двигательной активности выделен двумя вертикальными линиями красного цвета.




Рис. 2. Электромиосигнал при тестовой нагрузке (а) и его сегмент (б), на основе анализа которого формируются дескрипторы для классификатора мышечной усталости

Для формирования дескрипторов используем вейвлет-преобразование этого сегмента, эюра которого представлена на рис. 2б. Вейвлет-плоскость этого сегмента представлена на рис. 3. Вейвлет-плоскость построена для нижней частоты 20 Гц.

Для получения первой группы (вектора) дескрипторов используем формулу (5) на каждом уровне детализации i . Таким образом, размерность первого вектора дескрипторов определяется числом уровней детализации N или, другими словами, числом строк вейвлет-плоскости.




Рис. 3. Вейвлет-плоскость сегмента электромиосигнала

Максимальное количество уровней разложения определяется числом отсчетов в сигнале K , то есть $N_{\max}=K/2$. $N_{\min}$ или N непосредственно связано с частотой дискретизации (f_s) анализируемого сигнала. В случае разложения пЭМГ, дискредитированного с частотой 640 Гц при нижней частоте анализа равной 20 Гц, число уровней декомпозиции $N=200$ [5]. Таким образом, первый вектор будет иметь двести дескрипторов, определяемых по формуле (5).

Для определения компонентов второго вектора используем формулу, аналогичную (5), но энергию вейвлет-коэффициентов определяем по столбцам вейвлет-плоскости. В общем случае сегмент пЭМГ занимает порядка 1,5...2 с и в нем может быть свыше полутора тысяч отсчетов. Однако, если обратиться к вейвлет-плоскости рис. 3, то можно заметить, что максимальная энергия спектра сосредоточена в ее центре. Следовательно, задавшись пороговым значением для энергий в столбцах, можем использовать для вычисления компонентов второго вектора только те столбики, энергия в которых выше пороговой.

Результаты. В эксперименте, для исследования характера зависимости пЭМГ от МУ, пЭМГ снималась в зоне предплечья, где находятся такие мышцы, как поверхностный сгибатель пальцев, длинная ладонная мышца, лучевой сгибатель запястья и др. Одной из главных функций этих мышц является сгибание кисти. Для контроля величины нагрузки на кисть использовался динамометр электронный медицинский типа ДМЭР. Испытуемому ставилась задача с такой силой сжимать динамометр, чтобы на экране отображалось определенное значение: 5, 10, 15 и т.д. дан (*10 Ньютон). Таким образом, замыкалась биологическая обратная связь (БОС), которая позволяет связать регистрируемый параметр RMS с усилием динамометра. Общий вид кисти с динамометром и присоединенными электродами представлен на рис. 4.



Рис. 4. Общий вид кисти с динамометром и присоединенными электродами

Эксперимент начинался с установления индивидуальной шкалы пациента. Для этого устанавливалась нагрузка в динамометре и по секундомеру определялось время, после которого испытуемый уже не мог выполнять заданную процедуру, это время предельной МУ. Затем аналогичные эксперименты проводились у всех пациентов экспериментальной группы. Определялось среднее время предельной МУ. Затем, варьируя нагрузку в динамометре в сторону увеличения и в сторону уменьшения, устанавливалась единая шкала утомления для всех пациентов экспериментальной группы.

Гибридный классификатор построен на основе многоагентной идеологии. На нижнем уровне находятся автономные интеллектуальные агенты, формирующие пространство информативных признаков для автономных интеллектуальных агентов, находящихся на верхнем иерархическом уровне. На верхнем иерархическом уровне классификатора используем агрегатор, агрегирующий решения модулей классификации медицинского риска, находящихся на нижнем иерархическом уровне. Структура гибридного классификатора, построенного по такому принципу, представлена на рис. 5.




Рис. 5. Структура гибридной системы классификации

Она включает два независимых модуля классификаторов МУ, которые анализируют векторы дескрипторов (ВД 1 и ВД 2). В качестве агрегатора (мета-классификатора) была использована нечеткая нейронная сеть, алгоритмы настройки которой подробно описаны в [3, 6, 7], на выходе которого формируется окончательное значение показателя мышечной усталости.

Заключение. В результате проведенного исследования предложен метод контроля МУ, основанный на построении вейвлект-плоскостей сегментов пЭМГ, определении двух векторов дескрипторов по общим энергиям в строках и столбцах вейвлет-плоскости, и определения уровня МУ посредством гибридного классификатора, содержащего два независимых классификатора, выполненных на полносвязных нейронных сетях прямого распространения сигнала, и нечеткой нейронной сети в качестве агрегатора решений этих классификаторов.

Предложен способ формирования шкалы МУ, позволяющий использовать ее независимо от физических возможностей пациента, а также использовать в обучающих и контрольных выборках дескрипторы, полученные от пациентов, с различными значениями предельной МУ.

Библиографический список

1. Maddalena Mugnosso, Francesca Marini, Michael Holmes, Pietro Morassol and Jacopo Zenzeri. Muscelfatigue assessment during robot-mediated movements// Mugnosso et al. Journal of Neuro Engineering and Rehabilitation (2018) 15:119. Pp. 2–14. <https://jneuroengrehab.biomedcentral.com/articles/10.1186/s12984-018-0463-y>.
2. Способ оценки мышечной усталости на основе контроля паттернов синергии и устройство для его осуществления/Филист С.А., Трифонов А.А., Кузьмин А.А., Сафронов Р.И., Петрунина Е.В. Патент на изобретение 2766764 С1, 15.03.2022. Заявка № 2021105609 от 04.03.2021.
3. Гибридный метод контроля мышечной усталости в робототехнической системе / А. А. Кузьмин, Р. А. Томакова, Е. В. Петрунина, Д. А. Ермаков, С. Кадырова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информати-

ка. Медицинское приборостроение. 2023. Т. 13, № 3. С. 64–81. <https://doi.org/10.21869/2223-1536-2023-13-2-64-81>.

4. Victoria A. Salazar Herrera, J. Franklin Andrade Romero, Mauricio Amestegui Moreno. Algorithm of detection and alert of muscle fatigue in paraplegic patients, by Digital Signal Processing of Surface Electromyogram // IWSSIP 2010 – 17th International Conference on Systems, Signals and Image Processing. Pp.530-533.

5. DWT analysis of numerical and experimental data for the diagnosis of dynamic eccentricities in induction motors / J. Antonino-Daviu [et al.] // Mechanical Systems and Signal Processing. 2007. Vol. 21. No.6. P. 2575- 2589.

6. Шаталова, О.В. Биомедицинская спектроскопия в классификаторах функционального состояния органов и систем человека, построенных на основе гибридных технологий искусственного интеллекта / О.В. Шаталова, А.В. Серебровский, Н.С. Стадниченко, А.Ю. Новоселов, А.В. Лях // Системный анализ и управление в биомедицинских системах. – 2023. – Т. 22, № 2. – С. 100-113.

7. Петрунина Е. В., Томакова Р. А., Филист С. А. Гибридные методы и модели для биотехнических систем с адаптивным управлением диагностическими и реабилитационными процессами / Юго-Западный государственный университет. Курск, 2022. 249 с.

METHOD OF FORMING DESCRIPTORS FOR MUSCLE FATIGUE CLASSIFIERS BASED ON WAVELET ANALYSIS OF ELECTROMYOSIGNAL SEGMENTS

Elena V. Petrunina

Moscow Polytechnic University,
107023, Russia, Moscow, BolshayaSemenovskayast., 38
ekaterinazyankina@gmail.com

Alexander E. Pshenichny

Southwestern State University,
30500, Russia, Kursk, 50th Anniversary of October St., 94
SFilist@gmail.com

Dmitry A. Ermakov

Southwestern State University,
30500, Russia, Kursk, 50th Anniversary of October St., 94
dmitriyermakov98@yandex.ru

The article presents a description of methods for forming descriptors for classifiers of the degree of muscle fatigue in multi-agent hybrid machine learning systems. Descriptors are calculated by analyzing the evolution of the wavelet plane of electromyogram segments during the test load. A method for obtaining a muscle fatigue scale is proposed, which allows taking into account the patient's physical capabilities when forming training samples for the machine learning system.

Key words: surface electromyography, muscle fatigue, biomedical signal processing, wavelet analysis, descriptors, neural networks.

НЕЙРОСЕТЕВАЯ СИСТЕМА ДИАГНОСТИКИ САХАРНОГО ДИАБЕТА

Лукин Максим Константинович

НИУ «Высшая школы экономики»

614068, Россия, г. Пермь, ул. Студенческая, 38

mklukin@hse.edu.ru

В статье представлено описание разработки нейросетевой системы для прогнозирования результатов диагностики сахарного диабета на основе анамнеза пациента. Система позволяет с большой точностью предсказать вероятность выявления диабета при дальнейших лабораторных исследованиях. С помощью разработанной интеллектуальной системы проведено исследование предметной области и выявлены закономерности, имеющие практическое значение. **Ключевые слова:** искусственный интеллект, нейросетевые технологии, прогнозирование, сахарный диабет, анамнез.

Введение. Определение наличия сахарного диабета на основе результатов анализов может быть легко выполнено, но не всем доступно посещение больницы для этой цели. Вместо этого, большинство людей полагаются на субъективные показания, которые сложнее использовать для прогнозирования. Из-за этого было принято решение использовать анамнез для предсказания наличия сахарного диабета, основываясь на результатах опроса и обследования пациентов в больнице. Любой человек может ответить на простые вопросы о своем состоянии и узнать, нужно ли ему обратиться к врачу для профессионального обследования.

Однако исследования на тему прогнозирования вероятности сахарного диабета на основе анамнеза были проведены недостаточно подробно [4], хотя существуют материалы в интернете, которые содержат в основном те же вопросы для сбора анамнеза, что и в данном проекте. Основная цель работы заключается в сборе публичных данных об анамнезе людей и результатов наличия сахарного диабета на основе полноценного врачебного исследования, а также в создании и обучении нейросетевой модели на этих данных. Конечной целью является создание нейросетевой системы, которая сможет корректно прогнозировать вероятность наличия сахарного диабета у человека.

Для создания нейросетевой системы были выбраны следующие параметры:

X1 – возраст (age)

X2 – пол (gender)

X3 – увеличенное мочеобразование (polyuria)

X4 – чрезмерная жажда (polydipsia)

X5 – внезапная потеря веса (sudden_weight_loss)

X6 – слабость (weakness)

X7 – повышенный аппетит (polyphagia)

X8 – генитальная молочница (genital_thrush)

- X9 – ухудшение зрения (visual_blurring)
- X10 – зуд (itching)
- X11 – раздражительность (irritability)
- X12 – замедленное заживление ран (delayed_healing)
- X13 – слабость в мышцах (partial_paresis)
- X14 – неподвижность, онемение мышц (muscle_stiffness)
- X15 – выпадение волос (alopecia)
- X16 – ожирение (obesity)

Выходной параметр – сведения о наличии/отсутствии сахарного диабета.

Обучающее множество было собрано с помощью интернет-ресурса kaggle [1]. Изначально в множестве было 517 примеров. Перед переходом к проектированию и обучению нейросетевой модели была необходима очистка исходного множества от противоречивых примеров и выбросов. Обучив нейронную сеть на основе обучающего и валидирующего множеств, была проведена проверка обучающего множества (вместо тестового) для поиска выбросов в обучающем множестве.

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 шестнадцать входных нейронов, один выходной и один скрытый слой с тремя нейронами. Большее количество нейронов было не целесообразно, так как чем грубей сеть, тем меньше риск наткнуться на переобучение сети.

Для оценки корректной работы спроектированной нейронной сети использовалось тестирующее множество, состоящее из 77 примеров. Средняя относительная ошибка тестирования составила 3.2%, что можно считать приемлемым результатом. На рис. 1 представлена гистограмма, демонстрирующая сравнение между фактическими и прогнозируемыми нейросетью показателями.




Рис. 1. Результат тестирования нейросети

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», результат отображен на рис. 2.




Рис. 2. Значимость параметров

Как видно из рис. 2, наиболее значимыми являются polydipsia она же сухость во рту и polyuria – повышенное мочеобразование. Это подтверждается данными от дантистов и других врачей [9-10]. Ожидалось, что самым влиятельным параметром будет ожирение, так как рацион с повышенной калорийностью и вероятное присутствие большого количества сладкой и жирной еды провоцирует не только ожирение, но и приводит к нарушениям в организме, ведущим за собой сахарный диабет (чаще 2 типа).

Далее было проведено исследование полученных зависимостей между входными параметрами и медицинскими показателями. Исследование производилось с помощью метода «замораживания» [2-4, 8], суть которого заключается в варьировании значения одного параметра и фиксировании значений всех других параметров. Для этой цели был отобран «нейтральный пример», для которого нейросеть давала ответ, средне отличный от 0 и 1.

На рис. 3 показан график зависимости прогнозируемой вероятности положительного диагноза диабета от возраста. Из графика видно, что с увеличением возраста пациента, шанс положительного диагноза диабета возрастает. Начиная с 75 лет шанс получить диабет гораздо выше, чем в более молодом возрасте.




Рис. 3. Зависимость вероятности диабета от возраста

На рис. 4 продемонстрирована зависимость наличия диабета от наличия онемения мышц. Исходя из графика, можно заметить, что зависимость прямая.



Рис. 4. Вероятность диабета в зависимости от неподвижности мышц

На рис. 5 продемонстрирована зависимость наличия диабета от увеличенного мочеобразования. Исходя из графика, можно сделать вывод о том, что зависимость прямая.

Полученные результаты исследований не противоречат реальности, что подтверждает, что спроектированную нейронную сеть с помощью «Нейросимулятор 5» можно считать пригодной для прогнозирования наличия диабета у пациента.

Далее спроектируем нейронную сеть с помощью библиотеки Keras на языке Python. В результате оптимизации спроектированная нейронная сеть представляла собой персептрон, который имеет пять входных нейронов, один выходной и один скрытый слой с двумя нейронами. На рис. 6 изображен график обучения нейросети в Python.




Рис. 5. Вероятность диабета в зависимости от увеличенного мочеобразования




Рис. 6. График обучения сети в Python

После обучения нейронной сети было произведено сравнение фактических и прогнозных значений наличия диабета у пациента, результаты представлены на рис. 7:




Рис. 7. Фактические и прогнозные значения наличия диабета у пациента

При анализе данного графика можно сделать вывод, что погрешность немного выше, чем в Нейросимуляторе. Средняя относительная ошибка тестирования составила $MSE=0.017$, $RMSE=0.13$, что можно считать приемлемым результатом, а коэффициент детерминации в питоне $R^2=0.924$, а коэффициент детерминации в Нейросимуляторе 5 был равен $R^2=0.987$.

Для сравнения результатов анализа нейросети построенной в Нейросимулятор 5 и Python, было принято решение построить графики зависимости вероятности диабета от возраста (см. рис. 8) и зависимости вероятности диабета от онемения мышцах (см. рис. 9).

Исходя из графика 8, можно заметить, что вероятность наличия диабета у пациента повышается с увеличением его возраста. Такая же тенденция наблюдалась и при анализе на «Нейросимулятор 5».




Рис. 8. Зависимость наличия диабета от возраста пациента Python

На рис. 9 можно заметить, что зависимость диабета от онемения мышц прямая. Такая же тенденция была при анализе на «Нейросимулятор 5».




Рис. 9. Зависимость вероятности диабета от онемения мышц Python

Зависимости наличия диабета у пациента от параметров у «Нейросимулятора 5» и Python могут отличаться друг друга, так как при работе с нейросимулятором, данные делились на обучающее, тестовое и валидирующее множество вручную, а в Python было автоматическое деление.

Заключение. Построена система нейросетевого прогнозирования заболевания диабетом. Спроектированная нейросетевая модель учитывает 16 входных параметров. Методом сценарного прогнозирования построены графики зависимостей прогнозируемого диагноза от изменения входных параметров. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать наличие диабета у пациента. Наиболее близким к действительности прогнозом является прогноз «Нейросимулятора 5», так как в нем существует возможность обучения и выборки данных вручную. Таким образом, это позволяет вносить изменения для выявления реалистичного прогноза. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать наличие диабета у пациента.

Библиографический список

1. kaggle.com – базы данных. [Электронный ресурс]. Режим доступа: <https://www.kaggle.com>
2. Yasnitsky L.N., Dumler A., Cherepanov F.M. The capabilities of artificial intelligence to simulate the emergence and development of diseases, optimize prevention and treatment thereof, and identify new medical knowledge. *Journal of Pharmaceutical Sciences and Research*. 2018. Т. 10. No 9. С. 2192-2200.
3. MedicalXpress [Электронный ресурс] // URL: <https://medical-xpress.com>. (Дата обращения 06.03.2023)
4. 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. Т. 850. С. 351-358.
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.
6. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
7. 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>
8. Диабет и заболевания пародонта, Скиба А. В., Терешина Т. П. // *Инновации в стоматологии*. 2014. № 1 (3). URL: <https://cyberleninka.ru/article/n/diabet-i-zabolevaniya-parodonta> (дата обращения: 06.03.2023 г.).
9. Современные аспекты патогенеза пародонтита у больных сахарным диабетом, Григорян К. Р., Барер Г. М., Григорян О. Р., Мельниченко Г. А., Дедов И. И. // *Сахарный диабет*. 2006. № 2. URL: <https://cyberleninka.ru/article/n/sovremennyye-aspekty-patogeneza-parodontita-u-bolnyh-saharnym-diabetom> (дата обращения: 06.03.2023 г.).

NEURAL NETWORK SYSTEM FOR PREDICTING THE WINNER OF A SNOOKER MATCH

Lukin Maksim K.

Perm National Research University, Higher School of Economics
614068, Russia, Perm, Studencheskaya str. 38,
mklukin@hse.edu.ru

The paper describes the development of a neural network system for predicting the results of diabetes diagnosis based on a patient's medical history. The system allows predicting with great accuracy the probability of diabetes detection during further laboratory tests. The developed intelligent system was used to investigate the subject area and identify patterns of practical relevance.

Keywords: artificial intelligence, neural network technology, prognosis, diabetes mellitus, anamnesis.

НЕЙРОСЕТЕВАЯ КЛАССИФИКАЦИЯ РЕЗУЛЬТАТОВ ДИАГНОСТИКИ ХРОНИЧЕСКОЙ СЕРДЕЧНОЙ НЕДОСТАТОЧНОСТИ МЕТОДОМ ТЕНЗИОМЕТРИИ

Грибков Дмитрий Николаевич

Пензенский государственный университет
440026, г. Пенза, ул. Красная, 40
rororol23@mail.ru

Горбаченко Владимир Иванович

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

Потапов Владимир Владимирович

Донецкий государственный медицинский университет имени М. Горького
83003, г. Донецк, пр. Ильича, 16
x3x3x23@rambler.ru

Милтых Илья Сергеевич

Пензенский государственный университет
440026, г. Пенза, ул. Красная, 40
ilia@miltykh.com

Зенин Олег Константинович

Пензенский государственный университет
440026, г. Пенза, ул. Красная, 40
zen.olegz@gmail.com

Работа посвящена ранней диагностике хронической сердечной недостаточности (ХСН) с использованием тензиометрических показателей сыворотки и плазмы крови. Для обнаружения патологии решена задача классификации, возникающая при анализе результатов тензиометрического анализа. Рассмотрены два варианта классификации. В первом варианте классифицировались результаты тензиометрического исследования капли жидкой части крови при достижении равновесия. Использована полносвязная нейронная сеть и достигнута точность 97%. Во втором варианте исследовались тензиометрические характеристики в период динамического равновесия капли крови. С помощью рекуррентной нейронной сети проводилась классификация многомерных временных рядов. Достигнута точность 99%. Кроме того, результаты исследования свидетельствуют о возможности модернизации тензиометров за счет отказа от технических элементов, обеспечивающих принудительные осцилляции капли, что существенно удешевит прибор и уменьшит время проведения эксперимента.

Ключевые слова: сердечная недостаточность, ишемическая болезнь сердца, тензиометрия, поверхностное натяжение крови, нейронные сети, генерация синтетических данных, классификация временных рядов.

Введение. Хроническая сердечная недостаточность (ХСН) – грозное осложнение сердечно-сосудистой патологии [1–2]. Её ранняя диагностика является актуальной задачей современной медицины. Возможность использования тензиометрических параметров сыворотки и плазмы крови показана в [3–4].

Эксперименты проводились по методологии [5] с использованием аппаратно-программного комплекса РАТ-1 фирмы Sinterface Technologies. В эксперименте можно выделить три периода (рис. 1):

1) период динамического равновесия; 2) период вынужденных колебаний капли, создаваемых специальной помпой; 3) период достижения равновесия.




Рис. 1. Примеры графиков временных рядов

а) пациент без патологии, б) пациент с патологией,

1 – период динамического равновесия, 2 – период вынужденных колебаний капли,
3 – период достижения равновесия,

ST (surfacetension) – поверхностное натяжение образца, мН/м;
Area – площадь поверхности исследуемого образца, мм²;
Volume – объем исследуемого образца, мм³

После достижения равновесия можно определить патологическое состояние по тензиометрическим характеристикам. Однако основным ограничением данного подхода является проблема выбора объективного критерия для диагностики патологического состояния. Тензиометрические характеристики при равновесии для различных образцов сыворотки или плазмы представлены в виде табличного набора данных. Выявление наличия или отсутствия патологии является проблемой при классификации табличных данных. Для решения этой проблемы авторы предложили применить машинное обучение. Эксперименты с различными моделями машинного обучения показали, что наибольшую точность в 90% среди классических методов машинного обучения обеспечили деревья решений. Использование нейронных сетей [6] позволило значительно повысить точность.

Наиболее сложным с точки зрения технического обеспечения (дорогостоящая помпа, создающая колебания; сложный процесс калибровки; настройка программного обеспечения и т. д.) является второй период эксперимента. Если бы можно было обойтись без периода колебаний и при этом не страдала бы точность определения значений параметров, характеризующих поверхностное натяжение, это позволило бы существенно снизить стоимость и ускорить проведение эксперимента. Возникает вопрос о том, что можно было бы ограничиться первым периодом эксперимента. Данные первого этапа представляют собой многомерные временные ряды, классификация которых является сложной задачей. Решение этой задачи является целью работы – решить задачу классификации динамических характеристик тензиометрического исследования жидкой части (плазмы и сыворотки) крови путем классификации многомерных времен-

ных рядов с использованием результатов первого периода эксперимента – динамического равновесия.

Нейросетевая классификация табличных данных. Нейросетевая классификация табличных данных тензиометрии подробно описана в работе авторов [6]. Для обучения нейронной сети использовался набор данных, содержащий значения поверхностного натяжения и дилатационной вязкости, полученные в результате тензиометрических исследований жидкой части крови (плазмы и сыворотки) здоровых добровольцев и лиц, страдающих ХСН [7], а также пол и возраст пациента. Набор данных содержит измерения параметров сыворотки крови 65 здоровых добровольцев в возрасте от 44 до 72 лет (средний возраст $59,1 \pm 2,3$ года) и 67 пациентов с ишемической болезнью сердца (ИБС) в возрасте от 42 до 76 лет с ИБС (III класс по NYHA).

Для увеличения количества обучающих примеров использовалась аугментация табличных данных с помощью вариационного автоэнкодера (VAE) [8], реализованного в библиотеке Deep tabular augmentation [9]. В результате было сгенерировано 660 примеров. Эксперименты показали близость статистических характеристик реальных и сгенерированных данных.

В качестве нейросетевого классификатора реализована полносвязная трехслойная нейронная сеть с 64 нейронами в каждом слое. В скрытых слоях в качестве функции активации использован гиперболический тангенс. В выходном слое – функция softmax. Сеть обучалась с помощью алгоритма Adam. Для контроля переобучения и тестирования сети применялась перекрестная (hold-out cross-validation), с выделением 64% примеров для обучения, 16% – для проверки и 20% – для тестирования обученной сети.

Разработанный классификатор обеспечил высокие значения метрик качества классификации [10]. Доля правильных ответов (точность) равна 0,97. Точность предсказания патологии равна 0,98, точность предсказания отсутствия патологии равна 0,96. Чувствительность, т. е. доля правильно классифицированных примеров для случая патологии равна 0,96, а для случая отсутствия патологии – 0,98. ROC-кривая близка к идеальной, площадь под ROC-кривой равна 0,97.

Хотя нейросетевой классификатор статических табличных данных показал хорошие результаты, можно надеяться, что использование динамических тензиометрических характеристик позволит улучшить показатели. Однако это потребует решения достаточно сложной задачи классификации временных рядов.

Нейросетевая классификация временных рядов. Классификация динамических характеристик тензиометрического исследования плазмы крови представляет собой задачу классификации многомерных временных рядов. Временные ряды, описывающие результаты тензиометрии, являются многомерными, так как каждой временной отметке соответствует 8 показателей. Можно сказать, что по графикам изменения тензиометрических показателей (рис. 1) необходимо определить наличие патологии.

Анализ вариативности признаков показал, что наиболее вариативными признаками являются поверхностное натяжение образца, площадь поверхности исследуемого образца и объем исследуемого образца. Эти признаки использованы для обучения.

Для классификации временных рядов возможно применение различных методов машинного обучения [11–12]. Наиболее перспективным является применение различных типов нейронных сетей [13–14]. В простейшем подходе многомерные временные ряды могут быть представлены в виде векторов, а для классификации векторов может быть использована полносвязная нейронная сеть (многослойный перцептрон). Однако при использовании полносвязной сети не учитывается расположение признаков во времени, поэтому полносвязные сети не могут быть полностью использованы для классификации временных рядов.

Свёрточные нейронные сети успешно используются для классификации временных рядов [14]. В случае временных рядов свертку можно представить как использование и перемещение фильтра по заданному временному ряду. Фильтр также можно рассматривать как общее нелинейное преобразование временного ряда. Результат свертки (один фильтр) на входном временном ряду можно рассматривать как другой одномерный временной ряд, подвергнутый процессу фильтрации. Таким образом, применение нескольких фильтров к временному ряду приведет к получению многомерного временного ряда, размерность которого равна количеству используемых фильтров. Однако свёрточные сети обладают сложной архитектурой, что усложняет их обучение.

Для работы с временными рядами особенно перспективны рекуррентные нейронные сети [15] и нейронные сети с архитектурой трансформер [16], ориентированные на работу с последовательностями. Рекуррентные нейронные сети эффективно обрабатывают события, разделенные временными лагами с неопределенными длительностями и границами [17]. Из недостатков рекуррентных нейронных сетей можно отметить довольно длительное время обучения сети при большом числе временных шагов, однако работа уже обученного классификатора будет быстрой. Сети на основе трансформеров [14, 18–19] эффективны в различных задачах классификации временных рядов благодаря своей выдающейся способности улавливать долгосрочную зависимость, но обладают сложной архитектурой и сложны для обучения. В данной работе используется рекуррентная сеть, построенная на ячейках долгой краткосрочной памяти (LSTM – Long short-term memory) [15,20].

Экспериментальное исследование. Исходными данными для построения рекуррентной нейронной сети для классификации временных рядов послужил набор данных, содержащий результаты тензиометрических исследований плазмы и сыворотки крови, здоровых добровольцев и людей, страдающих ХСН. Исходный набор данных был несбалансированным и содержал всего 37 примеров для пациентов с ХСН. Чтобы сбалансировать набор и увеличить количество примеров была проведена аугментация исходных данных с использованием шума (jittering), поскольку другие виды дополнения могут исказить картину изменения параметров. Аугментация осуществлялась с помощью пакета NumPy и заключалась в формировании новых значений с помощью добавления к имеющимся данным нормально распределенных случайных чисел с нулевым математическим ожиданием и стандартным отклонением, равным 0,03. В результате было получено 3737 примеров без патологии и 3737 примеров с патологией. В наборе обучающих данных 70% примеров были использованы для обучения сети, а оставшиеся 30% – для валидации (проверки качества обучения).

Рекуррентная сеть реализована с использованием библиотек TensorFlow и Keras. Сеть реализована в виде ячейки LSTM со 128 нейронами в слоях. Для классификации примеров на два класса на выходе ячейки реализован полносвязный слой из двух нейронов с функцией активации softmax. Рекуррентная сеть обучалась реализованным в библиотеке Keras алгоритмом обратного распространения ошибки во времени (BPTT – back propagation through time) с использованием оптимизатора Adam. В качестве функции потерь использовалась бинарная перекрестная энтропия [20].

Результаты экспериментов (рис. 2) показали высокую скорость обучения и отсутствие переобучения сети.




Рис. 2. Изменение функции потерь (а) и точности классификации (б) на тренировочных и валидационных данных

Матрица ошибок (confusion matrix), построенная на тестовых данных, показывает высокую точность диагностики как наличия, так и отсутствия патологии (рис. 3).




Рис. 3. Матрица ошибок

Разработанный классификатор многомерных временных рядов обеспечил высокие значения метрик качества классификации. Доля правильных ответов (точность) равна 0,99. Точность предсказания патологии равна 0,99, точность предсказания отсутствия патологии равна 1,00. Чувствительность, т. е. доля правильно классифицированных примеров для случая патологии равна 1,0, а для случая отсутствия патологии – 0,99. ROC-кривая, показывающая соотношение между долей верно классифицированных примеров и долей неверно классифицированных примеров, близка к идеальной, площадь под ROC-кривой равна 0,99.

Заключение. Предложенный подход к ранней диагностике хронической сердечной недостаточности с помощью классификации временных рядов данных тензиометрического анализа крови продемонстрировал более высокую точность по сравнению с существующими подходами машинного обучения. Так, в обзоре [21] сообщалось о лучшей точности 96–97%, в статье [22] – о лучшей точности 97–98%, в [23] – о лучшей точности 96%. В работе [24] указано, что наилучший показатель AUC ROC составляет 0,90–0,92.

Таким образом, значения, характеризующие поверхностное натяжение жидкой части крови в период динамического равновесия, достаточны для определения ранних признаков развития ИБС. Это позволит модернизировать тензиометры путем отказа от технических элементов, обеспечивающих принудительные колебания капли, что значительно удешевит прибор и сократит продолжительность теста.

Учитывая постоянное развитие медицинских технологий и использование искусственного интеллекта, анализ тензиометрических данных с помощью нейронных сетей становится новым методом раннего выявления и дифференциальной диагностики сердечных заболеваний. Это позволит значительно повысить достоверность диагностики и начать терапевтические мероприятия на самых ранних стадиях заболевания, что тем самым значительно улучшит результаты лечения и улучшит прогноз жизни пациента.

Дальнейшее развитие исследований будет направлено на накопление обучающих данных и развертывание нейросетевой программы в виде приложения с удобным для врача интерфейсом.

Библиографический список

1. Chang G., Zhang W., Zhang M., Ding G. Clinical Value of Circulating ZFAS1 and miR-590-3p in the Diagnosis and Prognosis of Chronic Heart Failure // *Cardiovascular Toxicology*. 2021. Vol. 21. Issue 11. P. 880–888. DOI:10.1007/s12012-021-09678-7
2. Christiansen M.N., Køber L., Weeke P., Vasan R.S., Jeppesen J.L., Smith J.G., Gislason G.H., Torp-Pedersen C., Andersson C. Age-Specific Trends in Incidence, Mortality, and Comorbidities of Heart Failure in Denmark, 1995 to 2012 // *Circulation*. 2017. Vol. 135. No 13. P. 1214–23, DOI:10.1161/CIRCULATIONAHA.116.025941
3. Khomutov E.V., Dmitriev L.S., Potapov V.V., Zenin O.K., Zaitsev S.Yu. A New Approach to Calculating the Adsorption Characteristics of Low Molecular Blood Components of Patients with Heart Failure // *Optics and Spectroscopy*. 2023. Vol. 130. P. 503–510, DOI: 10.1134/S0030400X22100034
4. Хомутов Е.В., Дмитриев Л.С., Потапов В.В., Зенин О.К., Зайцев С.Ю. Адсорбционные характеристики низкомолекулярных компонентов крови больных с сердечной недостаточностью //

Известия Саратовского университета. Новая серия. Серия: Физика. 2022. Т. 22. Вып. 3. С. 244–253. DOI: 10.18500/1817-3020-2022-22-3-244-253

5. Potapov V.V., Shramenko E.K., Zenin O.K. Surface Tension and Dilatational Rheology of Blood in Patients Subjected to Cardiological Operations under Conditions of Artificial Circulation // *Colloid Journal*. 2020. Vol. 82. P. 49–53. DOI: 10.1134/S1061933X20010111

6. Algezweeni M.M., Gorbachenko V.I., Zenin O.K., Gribkov D.N., Potapov V.V., Milykh I. Early Diagnoses of Chronic Heart Failure using Neural Network Classifier of Tensiometric Blood Test Results // 2022 International Conference on Data Science and Intelligent Computing (ICDSIC); Karbala, Iraq: IEEE. 2022. P. 181–185. DOI: 10.1109/ICDSIC56987.2022.10076007

7. Свидетельство о государственной регистрации базы данных № 2022621033. База данных результатов тензиометрии сыворотки крови здоровых добровольцев и больных с хронической сердечной недостаточностью / В.В. Потапов, О. Зенин, И.Я. Моисеева, И.С. Милых. № 2021623094. заявл. 28.04.2022 : зарег. 05.05.2022.

8. Kingma D.P., Welling M. AutoEncoding Variational Bayes. arXiv:1312.6114. 2014, DOI:10.48550/arXiv.1312.6114

9. Schmidt L. Data Augmentation for Tabular Data. [Электронный ресурс]. Режим доступа: <https://medium.com/analytics-vidhya/data-augmentation-for-tabular-data-f75c94398c3e>

10. Брюс П., Брюс Э., Гедек П. Практическая статистика для специалистов DataScience. СПб.: БХВ-Петербург. 2021. 352 с.

11. Maharaj E.A., D'Urso P., Caiado J. Time series clustering and classification. Boca Raton: CRC Press, Taylor & Francis Group. 2019. 244 p.

12. Faouzi J. Time Series Classification: A review of Algorithms and Implementations // *Machine Learning (Emerging Trends and Applications)*. Proud Pen. 2022. P. 1–35. DOI:10.5772/intechopen.1004810

13. Ismail Fawaz H., Forestier G., Weber J., Idoumghar L., Muller P.-A. Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*. 2019. Vol. 33. P. 917–963, DOI: 10.1007/s10618-019-006191

14. Foumani N.M., Miller L., Tan C.W., Webb G.I., Forestier G., Salehi M. Deep Learning for Time Series Classification and Extrinsic Regression: A Current Survey. arXiv:2302.02515. 2023, DOI:10.48550/ARXIV.2302.02515

15. Salem F.M. Recurrent Neural Networks: From Simple to Gated Architectures. Cham: Springer-International Publishing. 2022. 144 p.

16. Kamath U., Graham K., Emara W. Transformers for Machine Learning: a Deep Dive; Boca Raton: CRC Press. 2022. 257 p.

17. Нильсен Э. Практический анализ временных рядов: прогнозирование со статистикой и машинное обучение. СПб.: ООО "Диалектика". 2021. 544 с.

18. Zha B., Vanni A., Hassan Y., Aldemir T., Yilmaz A. Deep Transformer Networks for Time Series Classification: The NPP Safety Case. arXiv:2104.05448. 2021. DOI: 10.48550/ARXIV.2104.05448

19. Wen Q., Zhou T., Zhang C., Chen W., Ma Z., Yan J., Sun L. Transformers in Time Series: A Survey arXiv:2104.05448. 2022, doi: 10.48550/ARXIV.2202.07125

20. Géron A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems. Sebastopol. O'Reilly Media, Inc. 2022. 861 p.

21. Tripoliti E.E., Papadopoulos T.G., Karanasiou G.S., Katerina K., Naka K.N., Fotiadis D.I. Heart Failure: Diagnosis, Severity Estimation and Prediction of Adverse Events Through Machine Learning Techniques // *Computational and Structural Biotechnology Journal*. 2017. Vol. 15. P. 26–47. DOI: 10.1016/j.csbj.2016.11.001

22. Yasmin F., Shah S.M.I., Naeem A. et al. Artificial intelligence in the diagnosis and detection of heart failure: the past, present, and future // *Reviews in Cardiovascular Medicine*. 2021. Vol. 4. No 22. P. 1095–1113. DOI:10.31083/j.rcm2204121

23. Jummal K., Jyothika K., Akhila B., Anusha K. Chronic Heart Failure Diagnosis from Heart Sounds Using Machine Learning and Full-Stack Deep Learning // *Journal of Coastal Life Medicine*. 2023. Vol. 11. No 2. P. 676–680. DOI: 10.31083/j.rcm2204121

24. Boccuto F., De Rosa S., Torella D., Veltri P., Guzzi P.H. Will Artificial Intelligence Provide Answers to Current Gaps and Needs in Chronic Heart Failure? // *Applied Sciences*. 2023. Vol. 13. No 13. 7663, DOI:10.3390/app13137663

NEURAL NETWORK CLASSIFICATION OF TENSIOMETRIC BLOOD TEST RESULTS FOR CHRONIC HEART FAILURE DIAGNOSIS USING TENSIOMETRY

DmitryN. Gribkov

Penza State University
Str. Krasnaya, 40, Penza, Russia, 440026
rororol23@mail.ru

Vladimir I. Gorbachenko

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

Vladimir V. Potapov

M. Gorky Donetsk State Medical University
Ave. Illyica, 16, Donetsk, 83003
x3x3x23@rambler.ru

IliaS.Miltykh

Penza State University
Str. Krasnaya, 40, Penza, Russia, 440026
contact@miltykh.com

Oleg K. Zenin

Penza State University
Str. Krasnaya, 40, Penza, Russia, 440026
zen.olegz@gmail.com

The paper is focused on early diagnosis of chronic heart failure (CHF) using tensiometric indices of serum and blood plasma. The classification problem arising from the analysis of the results of tensiometric analysis is solved for pathology detection. Two variants of classification were analyzed. The first option classifies the results of tensiometric analysis of a drop of liquid part of blood when equilibrium is reached. A fully connected neural network was used and an accuracy of 97% was achieved. The second option explored the tensiometric characteristics during the period of dynamic equilibrium of the blood drop. The recurrent neural network was used to classify multivariate time series. An accuracy of 99% was achieved. Besides, the results of the study indicate the possibility of modernisation of tensiometers by eliminating technical elements that provide forced oscillations of the drop, which will significantly reduce the cost of the device and reduce the time of the experiment.

Keywords: heart failure, ischaemic heart disease, tensiometry, surface tension of blood, neural networks, generation of synthetic data, classification of time series.

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ИНСУЛЬТА

Андреев Илья Витальевич

Пермский государственный национальный исследовательский университет,
ФИТ. 614068, Россия, г. Пермь, ул. Букирева, 15,
ilaandreev94@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования инсульта у пациента. Система позволяет с ~75% точностью определить вероятность инсульта у человека по его физиологическим показателям и индивидуальным характеристикам на данном этапе, а также спрогнозировать вероятность инсульта в будущем.

Ключевые слова: искусственный интеллект, нейросетевые технологии, инсульт, прогнозирование, закономерности.

Введение. В 2022 году ООН опубликовали данные, в котором были приведены самые главные причины смертей населения Земли. На лидирующей позиции который год остаётся смерть от ишемической болезни сердца. Вторую строчку по причине смертности занимает инсульт. Только за первые 7 месяцев от данного недуга погибло более шести миллионов человек по всему миру. Инсульт составляет примерно 11% от всего количества смертей. Современная статистика говорит о том, что с каждым годом число смертей от инсульта будет постоянно увеличиваться. Инсульт может настигнуть даже того, кто ведёт активный и здоровый образ жизни, однако систематическое прохождение обследований в медицинских учреждениях позволяют предотвратить около 78-80% случаев инсульта у человека. Область искусственного интеллекта постоянно развивается и внедряется в различные сферы деятельности, не обошла эта область и медицину. Искусственный интеллект уже довольно продолжительное время успешно применяется в медицине, а также постоянно совершенствуются различные методы. Стоит также отметить нашу Пермскую научную школу искусственного интеллекта [1-2], представители которой успешно разрабатывают и внедряют методы искусственного интеллекта в различные отрасли бизнеса и производства.

Основной целью работы является разработка нейросетевой модели, которая будет обучаться на основе реального датасета [3], который содержит информацию о людях, которые перенесли инсульт, а также о людях, которых это не коснулось.

После ознакомления с набором данных были определены следующие входные параметры, которые будут участвовать в обучении будущей системы.

x_1 – Пол

x_2 – Возраст

x_3 – Наличие гипертонии

x_4 – Наличие сердечно-сосудистых заболеваний

- x_5 – Нахождение в браке
- x_6 – Место проживания
- x_7 – Средний уровень глюкозы в крови
- x_8 – Индекс массы тела (ИМТ)
- x_9 – Отношение к курению

Так как в выбранном массиве данных некоторые параметры задаются текстовым описанием, то для дальнейшей работы по обучению нейросетевой модели необходимо закодировать эти значения в числовом виде. Результаты кодирования значений представлены далее (Таблица 1). Целевая переменная D_1 отображает факт перенесенного инсульта, где 0 – нет инсульта, а 1 – перенесён инсульт. После работы нейросетевая модель выдает вероятность инсульта у человека в диапазоне от 0 до 1.

Таблица 1

Кодирование значений некоторых входных параметров

Параметр	Значения
x_1	0 – женщина 1 – мужчина
x_3	0 – есть гипертония 1 – нет гипертонии
x_4	0 – нет сердечно-сосудистых заболеваний 1 – есть сердечно-сосудистые заболевания
x_5	0 – не в браке 1 – в браке
x_6	0 – село 1 – город
x_9	0 – бросил курить 1 – никогда не курил 2 – курит в настоящее время

Итоговое множество для обучения нейросетевой модели включало 539 примеров. Процесс проектирования, обучения и тестирования созданной нейросети проводилось в программе «Нейросимулятор 5». В результате проектирования нейронная сеть имеет структуру двуслойного перцептрона с двумя нейронами на скрытом слое. Графическое представление структуры можно наблюдать далее (см. рис. 1). Исходное множество было разбито на обучающее, валидирующее, тестирующее в соотношении 86%, 10%, 4% соответственно.




Рис. 1. Схематичное представление структуры перцептрона

После обучения нейросети проводилось её тестирование при помощи тестового множества. Средняя ошибка тестирования составила 24-25%, что можно считать удовлетворительным результатом для прогнозирования инсульта. На рис. 2 можно увидеть результаты проверки на тестирующем множестве. При оценке результатов значения, которые были выше 0.5 – определяли наличие инсульта, а то что ниже –отсутствие инсульта.




Рис. 2. Проверка работоспособности нейросети на тестовом множестве

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5». Далее представлены результаты проведенной оценки значимости входных параметров (рис. 3).




Рис. 3. Оценка значимости входных параметров

На данной диаграмме прекрасно видно, что параметром, который оказывает наибольшее влияние на появление инсульта, является возраст человека, что является истиной.

Далее в работе будут представлены исследования, которые будут затрагивать влияние некоторых входных параметров на вероятность возникновения

инсульта у человека. Для проведения данного исследования был выбран метод «Замораживания» [4]. Данный метод подразумевает выбор одного пациента с последующим изменением одного отдельного показателя и фиксированием других показателей. В качестве исследуемого пациента был выбран случайный человек из исходного множества. Его параметры приведены в табл. 2.

Таблица 2

Параметры исследуемого пациента

Параметр	Значение
Пол	Мужчина
Возраст	39
Наличие гипертонии	Нет
Наличие сердечно-сосудистых заболеваний	Нет
Нахождение в браке	Да
Место проживания	Город
Средний уровень глюкозы в крови	72.49
Индекс массы тела	44.9
Отношение к курению	Бросил

На рис. 4 отображена зависимость вероятности инсульта от возраста пациента. Прогнозирование выполнялось до 90 лет.




Рис. 4. Влияние возраста на вероятность инсульта

Как можно заметить на картинке, после 60 лет начинается довольно стремительное повышение риска инсульта у человека. Далее будут представлены графики, на которых будет отображено влияние других параметров на вероятность развития инсульта у пациента.




Рис. 5. Влияние гипертензии на развитие инсульта у пациента

Из представленного рисунка видно, что у человека, который имеет гипертензию, вероятность инсульта повышается намного раньше, чем у человека, у которого нет гипертензии. Влияние параметра, который отвечает за нахождения человека в браке представлен далее (рис. 6).




Рис. 6. Влияние брака на вероятность инсульта

По данному графику видно, что человек, который находится не в браке имеет повышенный шанс развития инсульта. Объяснить это можно тем, что в одиночестве у человека присутствует стресс и переживания, которые могут служить триггером для развития инсульта в будущем, однако этому можно противопоставить те случаи, когда брак был причиной развития инсульта у человека, так что данный вопрос требует дополнительных и более подробных исследований. Далее на графике (рис. 7) представлено влияние разного отношения к курению у человека.




Рис. 7. Влияние курения на развитие инсульта

Как бы это парадоксально не выглядело, но человек, который никогда не курил имеет повышенный риск, чем у людей, которые курят. Построенный график не может говорить о точном прогнозе, так как каждый человек имеет свои параметры, а значит и факт курения будет влиять на каждого по-разному. Последним исследованием влияния входных параметров на вероятность инсульта станет влияние уровня глюкозы в крови человека (рис. 8).




Рис. 8. Влияние уровня глюкозы в крови на развитие инсульта

На графике прекрасно видно, что чем выше уровень глюкозы в крови, тем выше вероятность появления инсульта у человека, что также доказано медицинскими учреждениями в различных работах.

Заключение. По результатам работы была создана нейросеть, которая позволяет оценивать вероятность инсульта по нескольким параметрам человека. Погрешность в 25% не является критичной для медицинской отрасли, если говорить о прогнозировании. Данную нейросеть можно использовать для выдачи рекомендаций пациенту, чтобы снизить вероятность инсульта в будущем. Используя прогнозирование, были получены сведения из изучаемой предметной области, которые могут быть полезны в будущем.

Библиографический список

1. 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. Т. 850. С. 351-358.
2. Yasnitsky L.N., Dumler A., Cherepanov F.M. The capabilities of artificial intelligence to simulate the emergence and development of diseases, optimize prevention and treatment thereof, and identify new medical knowledge // *Journal of Pharmaceutical Sciences and Research*. 2018. Т. 10. № 9. С. 2192-2200.
3. Набор данных для обучения [Электронный ресурс]. URL:<https://www.kaggle.com/fedesoriano/stroke-prediction-dataset>
4. Yasnitsky L.N. Artificial Intelligence and Medicine: History, Current State, and Forecasts for the Future // *Current Hypertension Reviews*, 2020, vol. 16, No 3. Pp. 210-215. DOI : 10.2174/1573402116666200714150953<https://pubmed.ncbi.nlm.nih.gov/32664841/>
5. Ясницкий Л.Н. Интеллектуальные системы. – М.: Лаборатория знаний, 2016. – 221 с.

NEURAL NETWORK SYSTEM FOR STROKE PREDICTION

Andreev Ilya V.

Perm State National Research University
15, Bukireva str, Perm, Russia, 614068,
ilaandreev94@gmail.com

The article describes the development of a neural network system for predicting stroke in a patient. The system allows to determine with ~75% accuracy the probability of a stroke in a person by his physiological indicators and individual characteristics at this stage, as well as to predict the probability of a stroke in the future.

Keywords: artificial intelligence, neural network technologies, stroke, forecasting, patterns.

РАЗРАБОТКА ВЕБ-ПРИЛОЖЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ ДИАГНОЗА У ПАЦИЕНТОВ С ЗАБОЛЕВАНИЕМ ЛЕГКИХ

Бреничев Никита Анатольевич

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

В статье представлено исследование и разработка веб-приложения для автоматической диагностики заболеваний легких на основе анализа медицинских изображений с применением методов машинного обучения. В качестве основного инструмента для классификации и распознавания патологий используются сверточные нейронные сети (CNN), которые показали высокую эффективность в задачах обработки изображений. Для увеличения объема обучающих данных применяются генеративные состязательные сети (GAN), что позволяет улучшить качество моделей при недостатке исходных данных. Разработанная система включает веб-интерфейс для загрузки изображений, микросервис прогнозирования и базу данных для хранения результатов.

Ключевые слова: нейронные сети, сверточные нейронные сети, генеративные сети, диагностика заболеваний легких, медицинские изображения.

Введение. Заболевания органов дыхания являются одними из самых распространенных причин заболеваемости и смертности по всему миру. [1] Ранняя диагностика этих заболеваний может значительно улучшить прогноз пациента, однако это требует высокой квалификации врачей и использования передовых технологий визуализации. Проблема ранней диагностики усугубляется нехваткой квалифицированных специалистов в области медицинской радиологии, что характерно не только для развивающихся стран, но и для многих регионов развитых стран. Это ведет к задержкам в постановке диагноза, что может негативно повлиять на результат лечения. Кроме того, человеческий фактор в диагностике всегда представляет собой риск ошибки: разные специалисты могут по-разному интерпретировать одни и те же изображения, что усложняет процесс установления точного диагноза.

В последние годы наблюдается значительное развитие технологий искусственного интеллекта (ИИ), в том числе машинного обучения (ML), что открыло новые возможности для автоматизации процесса диагностики заболеваний. Нейронные сети, такие как сверточные нейронные сети (CNN), продемонстрировали высокую эффективность в распознавании медицинских изображений. Они способны анализировать сложные данные, обнаруживая паттерны, которые могут быть неочевидны для человеческого глаза. Например, модели CNN могут быть использованы для автоматической классификации и сегментации изображений легких, выявления патологий, таких как опухоли или изменения в тканях.

Однако одной из ключевых проблем в обучении высокоточных моделей машинного обучения является недостаток данных. В медицине, особенно в случае редких заболеваний, сложно собрать большие и сбалансированные наборы данных. Кроме того, медицинские данные часто содержат конфиденциальную информацию, что затрудняет их свободное использование для научных исследований и разработки ИИ-моделей. В этом контексте генеративные состязательные сети (GAN) предоставляют уникальную возможность для создания синтетических данных, которые могут использоваться для обучения и улучшения моделей машинного обучения.

Исследование предметной области. Исследования в области применения нейронных сетей в медицине проводятся уже давно. Одна из работ [2] представляет возможности применения CNN в понимании медицинских изображений. В статье обсуждаются различные задачи, такие как классификация изображений, сегментация, локализация и обнаружение, а также применение CNN в анализе изображений мозга, груди, легких и других органов.

В статье с сравнением популярных CNN моделей [3] рассматриваются возможности в задачах обнаружения объектов и семантической сегментации в области медицинского анализа. Описываются случаи их применения в различных областях, а также их преимущества и недостатки.

Уже проводилась разработка систем по данной теме [4], где использовались нейронные сети для раннего предупреждения болезней по плевральному выпоту. Но в них использовались другие технологии и проводилось распознавание только изображений, без генерации дополнительных данных.

В данной использовались изображения плеврального выпота. Плевральный выпот представляет собой скопление жидкости в плевральной полости [5], это состояние обычно является симптомом различных заболеваний не только обычных инфекций легких, но и злокачественных новообразований и сердечной недостаточности.

В результате работы был разработан веб-сайт. Приложение состоит из трех основных компонентов: веб-интерфейса, микросервиса прогнозирования и базы данных. Веб-интерфейс предоставляет пользователю возможность авторизоваться, загружать изображения, получать результаты диагностики и просматривать историю распознаваний. Он реализован с использованием фреймворка Flask, который является популярным решением для создания веб-приложений на языке Python. Микросервис прогнозирования использует модель YOLO [6] для анализа изображений и классификации патологий. Язык программирования Python часто используется в задачах машинного обучения, а также имеет множество полезных библиотек.

Для обучения моделей использовался набор данных, предоставленный медицинскими учреждениями. Подобные данные обычно имеют следующий вид в стандартизированном формате – снимки клеток плевральной жидкости, взятые под прямым углом. Чтобы улучшить результаты обучения, применялись техники увеличения данных, включая генерацию изображений с помощью GAN. Сначала была проведена настройка этой модели, так называемый fine-

tune с помощью Dreambooth. Затем используется StableDiffusion для создания синтетических данных на основе реальных изображений.

Затем, были совмещены реальные и синтетические данные для обучения нейросети YOLO для распознавания медицинских патологий. Изображения классифицируются по 3 категориям: онкология, не онкология и другие патологии. В результате точность работы системы составила около 90% при тестировании.

Заключение. Разработанное веб-приложение представляет собой решение для автоматизации процесса диагностики заболеваний легких. Применение нейронных сетей позволило достичь высокой точности распознавания патологий, что может существенно помочь медицинским специалистам в их работе. Использование генеративных сетей для создания дополнительных данных способствует уменьшению влияния нехватки медицинских данных для обучения. Система, созданная с помощью этих средств, может помочь составлять прогнозы пациентам чаще и в больших объемах.




Рис. Результаты

Библиографический список

1. Thetop 10 causesofdeath. – URL: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death> (дата обращения: 02.05.2024). – Текст: электронный.
2. Sarvamangala D. R. Convolutional neural networks in medical image understanding: a survey / D. R. Sarvamangala, R. V. Kulkarni // *Evolutionary Intelligence*. – 2022. – Vol. 15. – Convolutional neural networks in medical image understanding. – № 1. – P. 1
3. Yang R. Artificial Convolutional Neural Network in Object Detection and Semantic Segmentation for Medical Imaging Analysis / R. Yang, Y. Yu. – Текст : электронный // *Frontiers in Oncology*. – 2021. – Т. 11. – URL: <https://www.frontiersin.org/journals/oncology/articles/10.3389/fonc.2021.638182/full> (датаобращения: 19.04.2024).

4. Проектирование и разработка прототипа информационной системы для диагностирования заболеваний – Национальный исследовательский университет «Высшая школа экономики», 2021 – (дата обращения: 23.04.2024).

5. Дифференциальная диагностика плевральных выпотов / М.И. Дюсьмикеева, Д.И. Горенок, О.А. Козлова, Е.М. Скрыгина, А.Е. Скрыгин, О.М. Залуцкая // Медицинская панорама. – 2014. – No7. – С. 66- 67.

6. Redmon, J. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi. // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2016. P. 779-788.

DEVELOPMENT OF A WEB APPLICATION TO DETERMINE DIAGNOSIS OF PATIENTS WITH LUNG DISEASE

Nikita A. Brenichev

HSE University,
Str. Studencheskaya, 38, Perm, Russia, 614070
brenichev@yandex.ru

The paper presents the research and development of a web application for automatic diagnosis of lung diseases based on the analysis of medical images using machine learning methods. As the main tool for classification and recognition of pathologies convolutional neural networks (CNN) are used, which have shown high efficiency in image processing tasks. Generative adversarial networks (GANs) are used to increase the amount of training data, which improves the quality of models when there is a lack of raw data. The developed system includes a web interface for downloading images, a prediction microservice and a database for storing results.

Keywords: neural networks, convolutional neural networks, generative networks, diagnosis of lung diseases, medical images.

УДК 004.8

О ТЕНДЕНЦИЯХ СОВРЕМЕННЫХ ИССЛЕДОВАНИЙ В ОБЛАСТИ МЕТОДОВ ОТБОРА ПРИЗНАКОВ

Черемухин Артем Дмитриевич

Нижегородский государственный инженерно-экономический университет,
606340, Россия, Нижегородская обл., г. Княгинино, ул. Октябрьская, 22а
ngie.u.cheremuhin@yandex.ru

В статье рассматривается актуальная проблема исследований отбора признаков в задачах машинного обучения. Исследование посвящено обобщению результатов зарубежных ученых в области отбора признаков за последнее время. Анализ статей показал, что большинство исследований проводится в области медицины и информационной безопасности.

Ключевые слова: отбор признаков, эволюционные алгоритмы, роевые алгоритмы.

Введение. Широкое использование различных методов и средств машинного обучения и анализа данных в практических задачах привело к появлению в организациях информационных систем, выполняющих в том числе задачи автоматического сбора и анализа информации. Это привело к двум основным последствиям:

- повысилась частота встречаемости исследовательских задач, когда по некоторому набору данных надо найти закономерности без наличия предположений о них;

- актуализировалась задача не просто решения задач машинного обучения, а эффективного – с минимумом временных и вычислительных затрат.

Достижение обоих выделенных целей предполагает выделение значимых и незначимых признаков – что привело к возрастанию важности процедуры feature selection; некоторые ученые считают именно эту процедуру одной из самых важных в процессе машинного обучения.

Постановка задачи и поиск работ. Как правило, цель отбора признаков состоит в том, чтобы оставить в выборке только признаки, непосредственно и значимо влияющие на зависимую переменную. Такая постановка задачи делает возможным применение соответствующих алгоритмов только к задачам классификации или регрессии, хотя есть примеры применения данных алгоритмов и к решению задачи кластеризации.

Цель данного исследования состоит в первичном обобщении результатов исследований иностранных ученых в области отбора признаков в последнее время для определения существующих краткосрочных трендов в данной области.

Для решения поставленной задачи были проанализированы все статьи, найденные на сайт scholar.google.com, название которых содержит словосочетание «feature selection» не раньше 2023 года.

Анализ полученных результатов. Статьи анализировались по следующим критериям:

- страна проведения исследований;
- применяемый метод отбора признаков и его класс;
- практическая область деятельности, к которой относится решаемая задача.

Полученные результаты представлены в таблице.

Таблица

**Описание найденных статей в области метода отбора признаков
с 2023 года**

Источник	Страна проведения исследований	Название метода отбора признаков и его класс	Практическая область деятельности решаемой задачи
[1]	Саудовская Аравия	bWWPA – авторский метаэвристический алгоритм, моделирующий природный процесс	-
[2]	Индия	Модифицированный метаэвристический алгоритм WPA-оптимизации, моделирующий агентное поведение людей в социуме	-
[3]	Саудовская Аравия	bDBERDTO – авторский гибридный алгоритм на основе двух алгоритмов, моделирующий поведение людей (BER) и поведение птиц (DTO)	Определение диабета у пациентов Медицина Задача классификации

Продолжение табл.

Источник	Страна проведения исследований	Название метода отбора признаков и его класс	Практическая область деятельности решаемой задачи
[4]	Великобритания	Три классических фильтрационных алгоритма – Фишера, Relief, sfbs-алгоритм	Определение гепатита у пациентов Медицина Задача классификации
[5]	Египет	bSCWDTO – авторский гибридный алгоритм на основе двух алгоритмов, моделирующий поведение птиц (DTO) и алгоритма оптимизации синус/косинус (SC)	-
[6]	Египет	ADGWDTO – авторский гибридный алгоритм на основе двух алгоритмов, моделирующий поведение птиц (DTO) и поведение стаи серых волков (GWO)	Предсказание скорости ветра Метеорология Задача регрессии
[7]	Турция	Классический фильтрационный алгоритм, оставляющий топ-пзначимых признаков	Определение вредоносного ПО Информационная безопасность Задача классификации
[8]	Турция	Классические фильтрационные алгоритмы – RFE, Boruta, sfbs	Предсказание факта разжижения почв Сейсмическая инженерия Задача классификации
[9]	Пакистан	Классический роевой алгоритм – алгоритм светлячков	Распознавание человека по походке Задача многоклассовой классификации
[10]	Индия	Новый алгоритм на основе использования преобразования Фурье	-
[11]	Марокко	Три классических алгоритма: генетический, алгоритм Harmony и гибридный GA-PSO(генетический алгоритм совместно с алгоритмом роевой оптимизации)	Определение диабета у пациентов Медицина Задача классификации
[12]	Китай	MGF2WL – новый графовый алгоритм на основе процедуры слияния графов	-
[13]	Китай	Классический фильтрационный алгоритм, оставляющий топ-пзначимых признаков	Диагностика аутических расстройств Медицина Задача классификации
[14]	Пакистан	Классический генетический алгоритм	Диагностика опухолей головного мозга Медицина Задача классификации
[15]	Новая Зеландия	IGRF-RFE – авторский гибридный алгоритм на основе классического рекурсивного удаления признаков (RFE), который проводится после первичного удаления неважных признаков после применения метода случайного леса	Обнаружение сетевых вторжений Информационная безопасность Задача классификации

Продолжение табл.

Источник	Страна проведения исследований	Название метода отбора признаков и его класс	Практическая область деятельности решаемой задачи
[16]	Китай	QGBWOA – авторская модификация классического роевого алгоритма (WOA) моделирующего поведение стаи горбатых китов	-
[17]	Иран	IBQANA – авторская модификация алгоритма, моделирующего навигацию птиц (HBO) с использованием стратегии бинарного поиска на основе расстояния (DBSS)	-
[18]	Китай	Три модифицированных алгоритма: CHMI, TF-CHI, TF-XGBoost	Классификация текстов Задача многоклассовой классификации
[19]	Египет	Гибридный алгоритм, основанный на основе двух алгоритмов, моделирующий поведение птиц (DTO) и поведение стаи горбатых китов (WOA)	Диагностика рака молочной железы Медицина Задача классификации
[20]	Саудовская Аравия	ASSOA – модифицированный алгоритм, моделирующий поведение белки	-
[21]	Саудовская Аравия	Авторский гибридный алгоритм на основе двух алгоритмов, моделирующий поведение птиц (DTO) и поведение стаи серых волков (GWO)	-
[22]			Обнаружение сетевых вторжений Информационная безопасность Задача классификации
[23]	Саудовская Аравия	Классический алгоритм, моделирующий поведение птиц (DTO)	Диагностика аритмии сердца по ЭКГ Медицина Задача классификации
[24]	Китай	FWNSDE _c – авторский алгоритм, основанный на алгоритме дифференциальной эволюции, включающий К-медоидную кластеризацию	Предсказание скорости ветра Метеорология Задача регрессии
[25]	Индия	Авторский гибридный алгоритм на основе двух алгоритмов: бинарной модификации алгоритма гравитационного поиска и моделирующего поведение стаи серых волков (GWO)	Диагностика киберугроз Информационная безопасность Задача классификации
[26]	Иордания	LS-PIO – авторская модификация метода оптимизации Pigeon на основе алгоритма локального поиска с запретами	Обнаружение сетевых вторжений Информационная безопасность Задача классификации
[27]	Египет	mSTOA – модифицированный алгоритм STOA	-
[28]	Китай	NRFSFN – авторский помехоустойчивый эвристический алгоритм для решения задачи многозначного обучения	-

Окончание табл.

Источник	Страна проведения исследований	Название метода отбора признаков и его класс	Практическая область деятельности решаемой задачи
[29]	Турция	Классический метод RFE	Обнаружение кибератак и аномалий Информационная безопасность Задача классификации
[30]	Иран	HLSFSGU – авторский алгоритм полууправляемого обучения, основанный на регуляризации графа Лапласа (GL) с использованием обобщенного некоррелированного ограничения	-
[31]	Китай	AFS – авторский адаптивный алгоритм отбора признаков	Диагностика неисправности оборудования Транспортная безопасность Задача классификации
[32]	Китай	GLFS – авторский алгоритм отбора признаков для случая многомерной классификации	-
[33]	Китай	Авторский модифицированный эволюционный алгоритм на основе оптимизации роя частиц(PSO)	-
[34]	Китай	MOFS-RFGA – Авторский модифицированный фильтрационный алгоритм ReliefF	-
[35]	Иран	SemiACO – авторская модификация алгоритма муравьиной колонии для случая полупараметрического обучения	-

Заключение. Анализ представленных исследований позволил сделать следующие предположения о тенденциях разработок в области метода отбора признаков:

- более половины рассмотренных работы приходится на авторов из Китая (10 работ) и Саудовской Аравии (6 работ);

- можно выделить три основные группы работ: чисто теоретические по разработке новых методов отбора признаков; исследования, фокусирующиеся на факторах, влияющих на наличие разных диагнозов; исследования, фокусирующиеся на обнаружении вредоносных вторжений и атак в информационные системы;

- основным фокусом исследователей является разработка новых гибридных алгоритмов, основанных на использовании в основном эволюционных или роевых алгоритмов.

Далее планируется продолжение и углубление проведенного анализа.

Библиографический список

1. Alhussan A. A. et al. A binary waterwheel plant optimization algorithm for feature selection //IEEE Access. – 2023.
2. Ganesh N. et al. Efficient feature selection using weighted superposition attraction optimization algorithm //Applied Sciences. – 2023. – Т. 13. – №. 5. – С. 3223.
3. Alhussan A. A. et al. Classification of diabetes using feature selection and hybrid Al-Biruni earth radius and dipper throated optimization //Diagnostics. – 2023. – Т. 13. – №. 12. – С. 2038.
4. Masood F. et al. Novel approach to evaluate classification algorithms and feature selection filter algorithms using medical data //journal of Computational and Cognitive Engineering. – 2023. – Т. 2. – №. 1. – С. 57-67.
5. Masood F. et al. Novel approach to evaluate classification algorithms and feature selection filter algorithms using medical data //journal of Computational and Cognitive Engineering. – 2023. – Т. 2. – №. 1. – С. 57-67.
6. El-Kenawy E. S. M. et al. Feature selection in wind speed forecasting systems based on meta-heuristic optimization //Plos one. – 2023. – Т. 18. – №. 2. – С. e0278491.
7. Şahin D. Ö. et al. A novel permission-based Android malware detection system using feature selection based on linear regression //Neural Computing and Applications. – 2023. – С. 1-16.
8. Demir S., Sahin E. K. An investigation of feature selection methods for soil liquefaction prediction based on tree-based ensemble algorithms using AdaBoost, gradient boosting, and XGBoost //Neural Computing and Applications. – 2023. – Т. 35. – №. 4. – С. 3173-3190.
9. Mehmood A. et al. Prosperous human gait recognition: An end-to-end system based on pre-trained CNN features selection //Multimedia Tools and Applications. – 2024. – С. 1-21.
10. Mahajan S., Pandit A. K. Hybrid method to supervise feature selection using signal processing and complex algebra techniques //Multimedia Tools and Applications. – 2023. – Т. 82. – №. 6. – С. 8213-8234.
11. Mohy-Eddine M. et al. An efficient network intrusion detection model for IoT security using K-NN classifier and feature selection //Multimedia Tools and Applications. – 2023. – Т. 82. – №. 15. – С. 23615-23633.
12. Li X., Zhang J., Safara F. Improving the accuracy of diabetes diagnosis applications through a hybrid feature selection algorithm //Neural processing letters. – 2023. – Т. 55. – №. 1. – С. 153-169.
13. Tang C. et al. Unsupervised feature selection via multiple graph fusion and feature weight learning //Science China Information Sciences. – 2023. – Т. 66. – №. 5. – С. 152101.
14. Zhang J. et al. Detection of autism spectrum disorder using fMRI functional connectivity with feature selection and deep learning //Cognitive Computation. – 2023. – Т. 15. – №. 4. – С. 1106-1117.
15. Sharif M. et al. Brain tumor segmentation and classification by improved binomial thresholding and multi-features selection //Journal of ambient intelligence and humanized computing. – 2024. – С. 1-20.
16. Yin Y. et al. IGRF-RFE: a hybrid feature selection method for MLP-based network intrusion detection on UNSW-NB15 dataset //Journal of Big Data. – 2023. – Т. 10. – №. 1. – С. 15.
17. Xing J. et al. Boosting whale optimizer with quasi-oppositional learning and Gaussian barebone for feature selection and COVID-19 image segmentation //Journal of bionic engineering. – 2023. – Т. 20. – №. 2. – С. 797-818.
18. Fatahi A., Nadimi-Shahraki M. H., Zamani H. An improved binary quantum-based avian navigation optimizer algorithm to select effective feature subset from medical data: A COVID-19 case study //Journal of Bionic Engineering. – 2024. – Т. 21. – №. 1. – С. 426-446.
19. Liu X. et al. Adapting feature selection algorithms for the classification of Chinese texts //Systems. – 2023. – Т. 11. – №. 9. – С. 483.
20. Atteia G. et al. Adaptive dynamic dipper throated optimization for feature selection in medical data //Computers, Materials & Continua. – 2023. – Т. 75. – №. 1. – С. 1883-1900.
21. Khafaga D. S. et al. Novel Optimized Feature Selection Using Metaheuristics Applied to Physical Benchmark Datasets //Computers, Materials & Continua. – 2023. – Т. 74. – №. 2.
22. Alkanhel R. et al. Network Intrusion Detection Based on Feature Selection and Hybrid Metaheuristic Optimization //Computers, Materials & Continua. – 2023. – Т. 74. – №. 2.
23. Khafaga D. S. et al. Dipper Throated Algorithm for Feature Selection and Classification in Electrocardiogram //Comput. Syst. Sci. Eng. – 2023. – Т. 45. – №. 2. – С. 1469-1482.
24. Lv S. X., Wang L. Multivariate wind speed forecasting based on multi-objective feature selection approach and hybrid deep learning model //Energy. – 2023. – Т. 263. – С. 126100.

25. Dey A. K., Gupta G. P., Sahu S. P. A metaheuristic-based ensemble feature selection framework for cyber threat detection in IoT-enabled networks //Decision Analytics Journal. – 2023. – T. 7. – C. 100206.
26. Alghanam O. A. et al. An improved PIO feature selection algorithm for IoT network intrusion detection system based on ensemble learning //Expert Systems with Applications. – 2023. – T. 213. – C. 118745.
27. Houssein E. H. et al. Boosted sooty tern optimization algorithm for global optimization and feature selection //Expert Systems with Applications. – 2023. – T. 213. – C. 119015.
28. Yin T. et al. Noise-resistant multilabel fuzzy neighborhood rough sets for feature subset selection //Information Sciences. – 2023. – T. 621. – C. 200-226.
29. Kilincer I. F. et al. Automated detection of cybersecurity attacks in healthcare systems with recursive feature elimination and multilayer perceptron optimization //Biocybernetics and Biomedical Engineering. – 2023. – T. 43. – №. 1. – C. 30-41.
30. Sheikhpour R., Berahmand K., Forouzandeh S. Hessian-based semi-supervised feature selection using generalized uncorrelated constraint //Knowledge-Based Systems. – 2023. – T. 269. – C. 110521.
31. Lao Z. et al. Intelligent fault diagnosis for rail transit switch machine based on adaptive feature selection and improved LightGBM //Engineering Failure Analysis. – 2023. – T. 148. – C. 107219.
32. Zhang J. et al. Group-preserving label-specific feature selection for multi-label learning //Expert Systems with Applications. – 2023. – T. 213. – C. 118861.
33. Hu Y. et al. A federated feature selection algorithm based on particle swarm optimization under privacy protection //Knowledge-Based Systems. – 2023. – T. 260. – C. 110122.
34. Xue Y., Zhu H., Neri F. A feature selection approach based on NSGA-II with ReliefF //Applied Soft Computing. – 2023. – T. 134. – C. 109987.
35. Karimi F., Dowlatshahi M. B., Hashemi A. SemiACO: A semi-supervised feature selection based on ant colony optimization //Expert Systems with Applications. – 2023. – T. 214. – C. 119130.

ON THE TRENDS OF MODERN RESEARCH IN THE FIELD OF FEATURE SELECTION METHODS

ArtemD. Cheremuhin

Nizhny Novgorod State University of Engineering and Economics,
Str. Oktyabrskaya, 22a, Knyaginino, Russia, 606340
ngieu.cheremuhin@yandex.ru

The article considers the current problem of feature selection research in machine learning tasks. The study is devoted to generalizing the results of foreign scientists in the field of feature selection in recent years. Analysis of articles showed that most of the research is carried out in the field of medicine and information security.

Keywords: feature selection, evolutionary algorithms, swarm algorithms.

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ВЕРОЯТНОСТИ ДИАБЕТА

Сидорова Татьяна Игоревна

Национальный исследовательский университет
«Высшая школа экономики»
ВШЭ 614107, Россия, г. Пермь, ул. Бульвар Гагарина, 37а,
e-mail: tatyana_sidorova_2603@mail.ru

В статье представлено описание разработки нейросетевой системы для прогнозирования вероятности диабета. Система позволяет с точностью от 80% предсказать данный диагноз на основе индивидуальных характеристик пациента. С помощью спроектированной нейросетевой системы проведено исследование предметной области и выявлены закономерности, имеющие практическое значение.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, диабет.

Введение. В связи с широким распространением нейросетевых технологий в настоящее время существует большое количество прогнозных моделей в сфере финансов, экономики, спорта и других. Возможности нейросетей в здравоохранении также активно изучаются исследователями. В частности, результаты трудов Пермской научной школы [1-5] свидетельствуют о том, что нейронные сети делают возможным прогнозирование продолжительности жизни, вероятности сердечного приступа и рака легких, а также отслеживание динамики развития заболевания.

Был проведен анализ научной литературы, в ходе которого выяснилось, что исследовательские работы по прогнозированию диабета на основе интеллектуальных систем практически отсутствуют. Научная статья Л.Ш. Черикбаевой [6] описывает прогнозирование диабета с помощью машинного обучения с использованием метода k-ближайших соседей. Диагноз прогнозируется на основе индивидуальных признаков и факторов риска. В данной статье доказана эффективность метода ближайших соседей относительно иных методов машинного обучения, однако в ней отсутствуют практические примеры прогноза и выводы о получении новых знаний, полезных для медицинских работников при работе с диабетом.

Основная цель данной работы заключается в сборе множества публичных данных о пациентах медицинских учреждений с симптомами диабета или утвержденным диагнозом, а также в создании и обучении нейросетевой модели на собранных данных. Предполагаемым результатом работы является нейросетевая система, прогнозирующая диабет на основе индивидуальных параметров пациента более, чем в 80% случаев.



Рис. 1. Доказательство адекватности нейронной сети

Постановка задачи. Для создания нейросетевой системы были выбраны 8 параметров: X1 – пол, X2 – возраст, X3 – наличие гипертензии, X4 – наличие заболеваний сердца, X5 – курение, X6 – индекс массы тела, X7 – уровень гемоглобина A1C в крови; X8 – уровень глюкозы в крови (в США измеряется в миллиграммах на децилитр). Выходной параметр – итоговый диагноз врача.

Обучающее множество было выбрано из материалов сайта Kaggle [7]. Автор датасета отмечает, что материалы были собраны на основе научных публикаций и данных медицинских учреждений. Перед переходом к проектированию и обучению нейросетевой модели данные были приведены к единому формату, а затем закодированы. Также были удалены выбросы и экстремальные значения, например, данные о пациентах младше 18 лет.

Объем итогового множества составляет 520 примеров. Данное множество было разделено на обучающее и тестирующее в соотношении 90% к 10% соответственно.

Проектирование нейронной сети. Проектирование, обучение, тестирование нейронной сети выполнялись с помощью программы «Нейросимулятор 5» [8] по методике [9]. Готовая нейронная сеть представляет из себя персептрон, который содержит 8 входных нейронов, 1 выходной нейрон и 3 нейрона в скрытом слое. Количество нейронов скрытого слоя было рассчитано по теореме Колмогорова-Арнольда [9].

Для оценки корректности работы системы использовалось тестирующее множество, состоящее из 52 примеров. Средняя квадратичная ошибка составила 19%, что можно назвать приемлемым результатом для сферы медицины. На рис. 1 представлена гистограмма, демонстрирующая разницу между фактическим диагнозом врача и вероятностью, прогнозируемой нейросетью.

Из результатов, отраженных на рис. 1, можно сделать вывод о корректной работе нейронной сети.

Исследование предметной области. С помощью программы «Нейросимулятор 5» была проведена оценка значимости параметров, результат которой представлен на рис. 2.




Рис. 2. Оценка значимости параметров

Как видно из рис. 2, наиболее значимыми параметрами являются гемоглобин A1C (гликированный гемоглобин), глюкоза в крови, возраст и индекс массы тела. Данные результаты являются вполне обоснованными с медицинской точки зрения. Анализ уровня гликированного гемоглобина незаменим для

диагностирования сахарного диабета: он входит в ряд профилактических анализов для определения диабета на ранней стадии и позволяет вовремя обнаружить неконтролируемые скачки глюкозы. Возраст пациента также имеет значение, поскольку с возрастом повышается риск инсулинорезистентности: по статистике заболевание развивается у людей старше 40 лет. Еще одним ключевым фактором риска выступает вес пациента, так как его избыток провоцирует усиленную выработку инсулина, вследствие чего восприимчивость организма к данному гормону снижается.

В качестве справочной информации ниже представлены нормальные значения значимых параметров:

- Гликированный гемоглобин: 4 – 6,5 ед.;
- Глюкоза: 70 – 100 мг/дл;
- Индекс массы тела: 18,5 – 25.

Далее были исследованы зависимости между входными параметрами и результатами прогнозирования. Исследование производилось путем выбора одного пациента и модификации его характеристик с целью отследить изменения вероятности диабета.

Пример 1. В примере 1 последовательно нормализуются наиболее значимые параметры, что в результате приводит к постепенному снижению вероятности заболевания. Объект прогнозирования – женщина 54 лет, имеющая болезнь сердца и табачную зависимость. Она имеет повышенный индекс массы тела (33,52) и повышенный уровень глюкозы (280). В целях «лечения» данного пациента гемоглобин (несмотря на то, что он находится в пределах нормы) был снижен с 6 до 4 единиц, затем последовательно глюкоза и индекс массы тела были снижены до верхних границ нормы (100 и 30 соответственно). На рис. 3 отражено изменение вероятности диабета.




Рис. 3. Последовательная нормализация значимых параметров на примере пациента №1

Как видно из рис. 3, после ликвидации высокого гемоглобина вероятность наступления диабета снижается со 100% до 8%. Поскольку данный параметр тесно связан с уровнем глюкозы, дальнейшая нормализация глюкозы снижает вероятность еще на 4%. Нормализация веса в данном случае незначительно повлияла на результат.

Таким образом, несмотря на наличие вредной привычки и болезни сердца, диабет возможно ликвидировать, направив усилия на снижение гликированного гемоглобина.

Пример 2. В данном примере процесс «лечения» производится в обратном порядке, путем поэтапного добавления здоровому пациенту факторов риска от наименее к наиболее значимым. Объект прогнозирования – мужчина 46 лет, который не курит и не имеет сердечно-сосудистых заболеваний. Его индекс массы тела и гемоглобин находятся в пределах нормы (24,93 и 5 соответственно), а уровень глюкозы составляет 100. В данной ситуации нейросеть прогнозирует диабет с вероятностью 3,5%. Далее последовательно были увеличены индекс массы тела (до 33,2), глюкоза (до 140) и гемоглобин (до 6,7). Процесс повышения вероятности заболевания представлен на рис. 4.

Как видно из гистограммы, повышение гемоглобина дает резкий скачок увеличения вероятности диабета с 3,5% до 11,5%, что еще раз доказывает высокое влияние гемоглобина на состояние пациента.

Пример 3. В данном примере отображена зависимость вероятности диабета от возраста, поскольку данный параметр также имеет высокую значимость. Прогноз проводится методом замораживания [9], который используется для оценки влияния определенного параметра на результат и заключается в варьировании одного из параметров, в то время как остальные данные остаются неизменными. Объект прогноза – женщина 25 лет, не имеющая табачной зависимости и сердечно-сосудистых заболеваний. Ее гемоглобин (6.1) находится в пределах нормы, однако уровень глюкозы в крови слегка и индекс массы тела повышены (158 и 28,5 соответственно). Данная пациентка является здоровой: нейросеть прогнозирует ей низкую вероятность диабета (8%). На рис. 5 отображено изменение вероятности диабета с увеличением возраста в том случае, если остальные параметры удастся сохранить прежними.




Рис. 4. Последовательное увеличение значимых параметров до уровня выше нормы у пациента №2




Рис. 5. Повышение вероятности диабета с увеличением возраста у пациента №3

Как видно из графика, один и тот же набор значений параметров по-разному влияет на пациента с течением времени. Для женщины из данного примера перечисленные выше значения параметров являются приемлемыми до

45 лет, однако после пересечения этого рубежа скорость роста вероятности диабета значительно увеличивается.

Таким образом, результаты, полученные в данных примерах, являются научно обоснованными и отражают существующую реальность. Следовательно, спроектированную нейросеть можно считать пригодной для прогнозирования вероятности диабета.

Заключение. Построена нейросетевая система для прогнозирования вероятности диабета. Спроектированная нейросетевая модель принимает на вход 8 параметров (включая индивидуальные характеристики пациента и факторы риска): пол, возраст, наличие гипертензии, наличие заболеваний сердца, курение, индекс массы тела, уровень гликированного гемоглобина и уровень глюкозы в крови. Методом сценарного прогнозирования построены графики зависимостей вероятности диабета от увеличения или уменьшения определенных показателей. Применение такого набора параметров в модели позволяет с высокой точностью прогнозировать вероятность развития диабета. Данный набор параметров может быть увеличен для более точного прогнозирования и получения глубинных знаний о предметной области.

Библиографический список

1. Yasnitsky L.N., Dumler A., Cherepanov F.M. The capabilities of artificial intelligence to simulate the emergence and Development of diseases, optimize prevention and treatment thereof, and identify new medical knowledge // *Journal of Pharmaceutical Sciences and Research*. 2018. Т. 10. № 9. С. 2192-2200.
2. 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. Т. 850. С. 351-358.
3. Завгородних Е.Д. Нейросетевая система прогнозирования сердечного приступа / Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. науч. ст. / Пермское отделение Научного совета при президиуме РАН по методологии искусственного интеллекта. – Пермь, 2022. – С. 79–84.
4. Дементьев М.А. Нейросетевая система прогнозирования продолжительности жизни человека / Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. науч. ст. / Пермское отделение Научного совета при президиуме РАН по методологии искусственного интеллекта. – Пермь, 2022. – С. 93–99.
5. Русаков В.В. Нейросетевая система прогнозирования рака лёгких / Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. науч. ст. / Пермское отделение Научного совета при президиуме РАН по методологии искусственного интеллекта. – Пермь, 2022. – С. 100 – 104.
6. Черикбаева Л.Ш. Прогнозирование диабета с использованием алгоритма машинного обучения k-ближайших соседей / Ф.У. Маликова, А.Т.Төлеушова, М.Ж.Болысханова, Б.Е.Балқашбай // *Вестник КазАТК*. – 2023. – №5. – С. 288 – 297. DOI 10.52167/1609-1817
7. Diabetespredictiondataset [Электронный ресурс] // Kaggle – Режим доступа: <https://www.kaggle.com/datasets/iammustafatz/diabetes-prediction-dataset/data>, свободный (дата обращения: 02.03.2024). – Загл. с экрана.
8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RU 2014612546. Заявка № 2014610341 от 15.01.2014.
9. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

NEURAL NETWORK SYSTEM FOR PREDICTING DIABETES PROBABILITY

Sidorova Tatyana I.

National Research University Higher School of Economics
Studencheskaya Street, 38, Perm, Russia, 614068, tatyana_sidorova_2603@mail.ru

The article describes the development of a neural network system for predicting the probability of diabetes. The system can accurately predict this diagnosis with an accuracy of 80% based on individual patient characteristics. Using the designed neural network system, a study of the subject area was conducted and patterns with practical significance were identified.

Keywords: artificial intelligence, neural network technologies, prediction, diabetes.

УДК 004.032.26

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ СЕРДЕЧНОГО ПРИСТУПА

Митюшкина Анна Владимировна

Пермский государственный национальный исследовательский университет, ФИТ
614068, Россия, г. Пермь, ул. Букирева, 15,
mityushkinaav@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования сердечного приступа у пациента. Система позволяет с ~80% точностью определить вероятность сердечного приступа у человека по его физиологическим показателям и индивидуальным характеристикам на данном этапе, а также спрогнозировать вероятность сердечного приступа в будущем.

Ключевые слова: искусственный интеллект, нейросетевые технологии, сердечный приступ, прогнозирование, закономерности.

Сердечно-сосудистые заболевания (ССЗ) являются причиной смерти номер один во всем мире. Выявление сердечно-сосудистых заболеваний является одним из способов увеличения продолжительности жизни. Особенное внимание уделяется выявлению факторов риска развития заболеваний сердца.

На данный момент существует множество различных работ, которые имеют схожую тематику и используют нейросетевые модели для прогнозирования сердечного приступа или других схожих заболеваний сердца. В статье [5] автор приводит метод DataMining с использованием нейросетей для выявления скрытых зависимостей различных параметров при прогнозировании сердечного приступа. В работе используется трёхслойный персептрон с применением метода обратного распространения. По результатам работы получилось добиться точности практически в 99%, что является отличным результатом.

Как и в случае со статьёй [5], в другой зарубежной статье [6] также приводится описание создания нейросетевой модели с использованием трехслойного персептрона с использованием такого же способа обучения – обратное распространение ошибки. Как и в случае с вышеописанной статьёй, в данном источнике авторы приводят результаты работы нейросетевой модели, основан-

ной на собранных медицинских данных. Точность системы составляет свыше 88%. Беря во внимание данные работы, в данной работе будет произведена попытка повторить результаты зарубежных учёных в данной области, однако в отличие от использования языка программирования Python будет использоваться наш отечественный инструмент «Нейросимулятор 5».

Основной целью работы является разработка нейросетевой модели, которая будет обучаться на основе реального датасета [3], который содержит информацию о людях, у которых был сердечный приступ, а также о людях, которых это не коснулось.

После ознакомления с набором данных были определены следующие входные параметры, которые будут участвовать в обучении будущей системы.

X1 – Возраст (от 40 до 95 лет)

X2 – Анемия (0 – нет 1 – да)

X3 – Показатель креатинин фосфокиназа (от 23 до 7861 нг/мл)

X4 – Диабет (0 – нет 1 – да)

X5 – Сердечный выброс (от 14 до 80 процентов)

X6 – Высокое кровяное давление (гипертония) 0 – нет 1 – да

X7 – Показатель тромбоцитов в крови (от 25100 до 850000 килотромбоциты/мл)

X8 – Уровень сывороточного креатинина в крови (от 0,5 до 9,4 мг/дл)

X9 – Уровень сывороточного натрия в крови (от 113 до 148 мг-экв/л)

X10 – Пол (0 – женщина, 1 – мужчина)

X11 – Показатель курения (0 – не курит, 1 – курит)

Выходной параметр D1 – вероятность сердечного приступа у человека в диапазоне от 0 до 1.

Итоговое множество для обучения нейросетевой модели включало 300 примеров. Процесс проектирования, обучения и тестирования созданной нейросети проводилось в программе «Нейросимулятор 5». В результате проектирования спроектированная нейронная сеть имеет структуру двуслойного перцептрона с одним нейроном на скрытом слое. Графическое представление структуры можно наблюдать далее (см. рис. 1). Исходное множество было разбито на обучающее, валидирующее, тестирующее в соотношении 80%, 20%, 10% соответственно.




Рис. 1. Схематичное представление структуры перцептрона

После обучения нейросети проводилось её тестирование при помощи тестового множества. Средняя ошибка тестирования составила 20%, что можно считать удовлетворительным результатом для прогнозирования сердечного приступа. На рис. 2 можно увидеть результаты проверки на тестирующем множестве. При оценке результатов значения, которые были выше 0.5 – определяли наличие сердечного приступа.



Рис. 2. Проверка работоспособности нейросети на тестовом множестве

Оценка значимости входных параметров была выполнена с помощью программы «Нейросимулятор 5». Далее представлены результаты проведенной оценки входных параметров (рис. 3).




Рис. 3. Оценка значимости входных параметров

На данной диаграмме прекрасно видно, что параметром, который оказывает наибольшее влияние на появление сердечного приступа, является уровень сывороточного креатинина в крови.

Далее в работе будут представлены исследования, которые будут затрагивать влияние некоторых входных параметров на вероятность возникновения сердечного приступа у человека. Для проведения данного исследования был выбран метод «Замораживания» [4]. Данный метод подразумевает выбор одного пациента с последующим изменением одного отдельного показателя и фикс-

сированием других показателей. В качестве исследуемого пациента был выбран случайный человек из исходного множества. Его параметры приведены в табл.

Таблица

Параметры исследуемого пациента

Параметр	Значение
Возраст	41
Анемия	Нет
Показатель креатинин фосфокиназа	148
Диабет	Нет
Сердечный выброс	39
Высокое кровяное давление	Нет
Тромбоциты в крови	374000
Уровень сывороточного креатинина в крови	0.8
Уровень сывороточного натрия в крови	140
Пол	Мужчина
Показатель курения	Да

На рис. 4 отображена зависимость вероятности сердечного приступа от сывороточного креатинина в крови пациента. Прогнозирование выполнялось до 75 лет.




Рис. 4. Влияние сывороточного креатинина в крови пациента

Как можно заметить на графике, чем выше показатель сывороточного креатинина, тем выше вероятность сердечного приступа. Далее будут представлены графики, на которых будет отображено влияние других параметров на вероятность развития сердечного приступа у пациента.




Рис. 5. Влияние сердечного выброса на развитие сердечного приступа у пациента

На рис. 5 продемонстрирована зависимость сердечной недостаточности от сердечного выброса. В данном случае можно сделать вывод, что этот показатель оказывает серьезное воздействие у склонных к заболеванию пациентов. Чем меньше сокращений (выбросов), тем больше становится вероятность сердечного приступа у пациента.




Рис. 6. Влияние креатинина фосфокиназа на вероятность сердечного приступа

По данному графику (рис. 6) видно, что при повышении значения креатинина фосфокиназа вероятность сердечного приступа растет в пределах нормы.

Выполнение исследования на языке Python. Для сравнения результатов исследование было проведено при помощи средств языка Python.




Рис. 7. Результат тестирования нейронной сети в Python

Средняя ошибка тестирования составила 16%, что можно считать приемлемым результатом. На рис. 7 представлена гистограмма, демонстрирующая

разницу между фактическим и прогнозируемым нейросетью итоговым результатом.

Из результатов, изображенных на рис. 1, можно сделать вывод об адекватной работе спроектированной нейронной сети. Далее было проведено исследование итоговых результатов прогнозирования сердечного приступа. Исследование также проводилось при помощи метода «замораживания» на тех же данных, что использовались в нейросимуляторе.

На рис. 8 показан график зависимости вероятности сердечного приступа от сывороточного креатинина в крови пациента.

На рис. 9 продемонстрирована зависимость сердечной недостаточности от сердечного выброса. В данном случае можно сделать вывод, что этот показатель оказывает серьезное воздействие у склонных к заболеванию пациентов.

По данному графику (рис. 10) видно, что при повышении значения креатинина фосфокиназа вероятность сердечного приступа растет в пределах нормы.




Рис. 8. Влияние сывороточного креатинина в крови пациента




Рис. 9. Влияние сердечного выброса на развитие сердечного приступа у пациента




Рис. 10. Влияние креатинина фосфокиназа на вероятность сердечного приступа

Заключение. По результатам работы была создана нейросеть, которая позволяет оценивать вероятность сердечного приступа по нескольким параметрам человека. Проведено исследование итоговых результатов нейросетей, построенных в нейросиммуляторе и средствами языка Python, выполнено их сравнение. Коэффициент детерминации в нейросимуляторе составил 52%, в Colab 37%. Методом сценарного прогнозирования построены графики зависимостей итогового результата от сывороточного креатинина в крови, сердечного выброса и креатинина фосфокиназа.

Библиографический список

1. 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. Т. 850. С. 351-358.
2. Yasnitsky L.N., Dumler A., Cherepanov F.M. The capabilities of artificial intelligence to simulate the emergence and development of diseases, optimize prevention and treatment thereof, and identify new medical knowledge // *Journal of Pharmaceutical Sciences and Research*. 2018. Т. 10. № 9. С. 2192-2200.
3. Набор данных для обучения [Электронный ресурс].
URL: <https://www.kaggle.com/datasets/andrewmvd/heart-failure-clinical-data>
4. Yasnitsky L.N. Artificial Intelligence and Medicine: History, Current State, and Forecasts for the Future // *Current Hypertension Reviews*, 2020, vol. 16, No 3. Pp. 210-215. DOI : 10.2174/1573402116666200714150953 <https://pubmed.ncbi.nlm.nih.gov/32664841/>
5. Dangare C., Apte S. A data mining approach for prediction of heart disease using neural networks // *International Journal of Computer Engineering and Technology (IJCET)*. – 2012. – Т. 3. – №. 3.
6. Al-Milli N. Backpropagation neural network for prediction of heart disease // *Journal of theoretical and applied information Technology*. – 2013. – Т. 56. – №. 1. – С. 131-135.

NEURAL NETWORK SYSTEM FOR HEART ATTACK PREDICTION

Mityushkina Anna V.

Perm State National Research University, FIT
Bukireva str., 15, Perm, Russia, 614068
mityushkinaav@gmail.com

The article presents a description of the development of a neural network system for predicting a heart attack in a patient. The system makes it possible to reliably determine the probability of a heart attack in a person with ~ 80% by assessing its signs and features of signs for the presence of increased danger, as well as predicting the likelihood of a heart attack in the future.

Key words: artificial intelligence, neural network technologies, heart attack, prediction, persecution.

УДК 616.12-009.72-06:616.127-005.8-008.6-036.11-07

ПОЧЕМУ СОВРЕМЕННЫЕ МЕДИКО-ДИАГНОСТИЧЕСКИЕ СИСТЕМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА РАБОТАЮТ ТАК ПЛОХО

Ясницкий Леонид Нахимович

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

Думлер Андрей Артурович

Пермский государственный медицинский университет
имени академика Е.А. Вагнера Минздрава РФ, Пермь, Россия
614000 Пермский край, г. Пермь, ул. Петропавловская 26
ivan.ivanovskii.2000@mail.ru

Приведено объяснение причин неудачных попыток создания и низкой точности современных медико-диагностических систем искусственного интеллекта.

Ключевые слова: Диагностика, причины неудач, Ноу Хау, прогнозирование прогрессирования заболеваний, образ жизни, прием лекарств, нейронная сеть.

Введение. В последнее время значительных успехов достигли нейросетевые системы медицинской диагностики, основанные на распознавании зрительных изображений – рентгеновских снимков, УЗИ и др. В нашем докладе этого вида медико-диагностических систем мы не касаемся. Речь идет только о нейросетевых системах медицинской диагностики регрессионного типа, основанных только на количественных данных об анамнезе заболеваний, жалобах пациентов, результатах лабораторных и инструментальных методов обследования.

Анализ литературных и интернет-источников показывает, что разработкой таких медико-диагностических систем занимается большое количество научных коллективов. Имеется информация о крупных инвестиционных вложениях в эти проекты. Однако, найти сообщения об их массовом практическом применении гораздо сложнее.

В качестве причин неудачных попыток создания таких систем мы видим как объективные, так и субъективные. Объективной причиной, несомненно, является исключительная сложность самого объекта моделирования – Человека.

Основная часть. В качестве субъективных причин мы можем указать следующие:

1. Принципиальные ошибки в самом фундаменте медицинской науки, алогизмы и нарушения Аристотелевской логики.

Тесно сотрудничая с медицинскими работниками, мы не раз наблюдали, как авторитетнейшие профессора ставили несовпадающие между собой диагнозы одному и тому же пациенту, убедительно обосновывая свои противоречивые заключения. Естественно, что нейронные сети, которые понимают только Аристотелевскую логику (а не врачебную) на таких конфликтующих между собой данных обучаться отказываются, или обучаются с большими погрешностями.

Если не подвергать сомнению высокую квалификацию спорящих между собой профессоров, то их разногласия можно объяснить только одним – слабостью самой медицинской науки.

Это наше заключение о слабости медицинской науки косвенно подтверждается известным высказыванием бывшего главного терапевта Минздрава России академика А.Г. Чучалина, заявившего, что «практически каждый третий диагноз ставится отечественными врачами неверно». Академик А.Г. Чучалин объясняет сей парадокс низким качеством профессиональной подготовки отечественных врачей. Но, не слишком ли много у нас неквалифицированных врачей? Тут явно напрашивается иное объяснение.

Мы полагаем, что парадокс объясняется элементарным несовпадением мнения академика А.Г. Чучалина и мнений этих самых «неквалифицированных» врачей.

Несовпадение мнений, а значит и несовпадение диагнозов, поставленных разными врачами – это довольно частое в медицине явление. Несомненно, оно является результатом слабости современной медицинской науки, наличием в ней алогизмов, которые бросаются в глаза математикам, но не замечаются врачами. Мы можем привести примеры обнаруженных нами алогизмов во многих медицинских областях, таких как кардиология, пульмонология, гастроэнтерология, онкология. Без понимания природы этих алогизмов и без применения специальных мер по их преодолению, приемлемые по точности нейросетевые медико-диагностические системы в принципе не могут быть созданы. Но пока мы не будем объяснять природу алогизмов и раскрывать способы их преодоления.

В нашей многолетней практике нам не раз приходилось наблюдать, как наличие медицинских алогизмов заводи́ли в тупик научные коллективы весьма серьезных компаний, таких как «Сбер» и даже МФТИ, взявшихся за создание нейросетевых медико-диагностических систем. Печально, но огромные инвестиции в такие проекты оказывались практически бесполезными.

2. Большое количество ошибочной информации в медицинских данных.

Данные медицинской статистики, взятые из историй заболеваний и электронных медицинских карт, часто изобилуют большим количеством ошибочной информации, обусловленной неточностью показаний медицинских приборов и результатов лабораторных исследований, ошибками и халатным отношением медицинского персонала. К сожалению, неверная информация в электронные медицинские карты попадает не только по указанным выше случайным причинам. Неправильные диагнозы иногда заносятся целенаправленно, например, для улучшения статистических показателей медицинских учреждений. Естественно, что нейронные сети, обученные на таких данных, не могут давать приемлемые результаты.

3. Неиспользование нетрадиционных знаний и данных о человеке.

Естественно, что правомерность использования нетрадиционных данных и знаний (эзотерических, астрологических, нумерологических и др.) должна подтверждаться научными экспериментами. И здесь никаких проблем в проведении таких экспериментов мы не видим. Создавая нейронные сети, мы обучаем их на одних примерах поведения предметной области, валидируем на других примерах и тестируем на третьих примерах, которых нейронная сеть никогда «не видела». И если при использовании нетрадиционных данных погрешность нейросетевых прогнозов на тестовом множестве оказывается меньше, чем без их использования, то такие примеры, несомненно, можно и нужно использовать. Современные же разработчики нейросетевых диагностических систем, к сожалению, этого, как правило, не делают.

Пермская диагностико-прогностическая система KARDIONET.

В результате тесного многолетнего сотрудничества математиков и медиков, нам удалось найти общий язык с врачами, и мы научились преодолевать медицинские алогизмы. Мы создали кардио-диагностическую систему KARDIONET, успешно внедренную в медицинскую практику и не совершившую за последние 10 лет ни одной ошибки ни в постановке диагнозов, ни в прогнозах на варианты прогрессирования заболеваний. Однако наши методики преодоления медицинских алогизмов и применения нетрадиционных данных и знаний мы пока не раскрываем. Но мы обещаем, что в случае получения инвестиций все наши Ноу Хау обязательно будут раскрыты.

Пермская кардио-диагностическая система KARDIONET, не смотря на свой более чем 15-летний возраст, по точности постановки диагнозов и своим функциональным качествам, намного превосходит существующие и вновь создаваемые аналоги. Как показано в наших публикациях [2-7], помимо собственно диагностики, KARDIONET позволяет прогнозировать появление и прогрессирование заболеваний на много лет вперед. Она позволяет подбирать оптимальный образ жизни пациента и приема некоторых лекарственных препаратов. Кроме того, она позволяет получать новые, неизвестные ранее, медицинские знания и закономерности, фиксировать и объяснять парадоксы теоретической медицины, такие как «парадокс курильщика», «парадокс алкоголика», «парадокс физзарядки».

Секрет успеха пермской диагностической системы KARDIONET заключается в следующем:

- в течение длительного времени мы прилагали усилия для того, чтобы найти общий язык между математиками и врачами. В результате мы научились в каждом конкретном случае решать проблему медицинских алогизмов;

- долго и настойчиво с помощью авторского алгоритма [1] мы выявляли и устраняли статистические выбросы, являющиеся результатом врачебных ошибок, результатом небрежности младшего медицинского персонала, результатом теоретических противоречий и разногласий между врачами и различными медицинскими научными школами;

- мы не пренебрегали нетрадиционными знаниями и параметрами.

Заключение. Авторы настоящего доклада понимают, что высказанное ими мнение является нетривиальным, необщепринятым и может показаться слишком ортодоксальным. Но, мы имеем на это право потому, что у нас есть многолетний опыт нейросетевого моделирования в самых разнообразных предметных областях. И мы имеем серьезный научный приоритет в этих областях. Этот научный приоритет отражен в наших публикациях и доказан в обзорных статьях [8, 9]. Например, как следует из этих обзорных статей, научными коллективами, под руководством одного из авторов настоящей статьи Л.Н. Ясницкого, первыми, либо в числе первых были показаны уникальные возможности практического применения нейронных сетей для решения актуальных задач во многих предметных областях, таких как промышленность, экономика, бизнес, политология, социология, психология, экология, образование, медицина, спорт и др.

Мы надеемся, что выполненный нами анализ причин неудач создания нейросетевых медицинских диагностических систем и наше нестандартное мнение будут правильно поняты, наши Ноу-Хау будут раскрыты и приняты на вооружение инвесторами и учеными, и нейронные сети займут в медицине место, не уступающее тому, какое они занимают во множестве других предметных областей.

Библиографический список

1. 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>
2. Yasnitsky L.N., Dumler A.A., Bogdanov K.V., Poleschuk A.N., Cherepanov F.M., Makurina T.V., Chugaynov S.V. Diagnosis and Prognosis of Cardiovascular Diseases on the Basis of Neural Networks // Biomedical Engineering. 2013. Vol. 47. No 3. Pp. 160-163. DOI: 10.1007/s10527-013-9359-0. SJR=0,54. <https://link.springer.com/article/10.1007/s10527-013-9359-0>
3. Yasnitsky L.N., Dumler A.A., Poleschuk 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. 7(2), BM-095-15, 8 pages. https://www.hse.ru/data/2015/09/30/1074486875/BM-095-15_Artificial-Neural-Networks-for..sease-Progr_2015_06_02_19_08_14.pdf
4. Yasnitsky L.N., Dumler A.A., Cherepanov F.M. The Capabilities of Artificial Intelligence to Simulate the Emergence and Development of Diseases, Optimize Prevention and Treatment Thereof, and Identify New Medical Knowledge // Journal of Pharmaceutical Science and Research. 2018. Vol. 10(9). Pp. 2192-2200. <http://www.jpsr.pharmainfo.in/Documents/Volumes/vol10Issue09/jpsr10091816.pdf>
5. Yasnitsky L.N., Dumler A.A., Cherepanov F.M. Dynamic Artificial Neural Networks as Basis for Medicine Revolution. In: Antipova T., Rocha A. (eds) Digital Science. DSIC18 2018. Advances in Intelli-

gent Systems and Computing, 2019. vol 850, pp. 351-358. Springer, Cham, https://doi.org/10.1007/978-3-030-02351-5_40.

6. Yasnitsky L.N., Dumler A.A., Cherepanov F.M. Robot-Doctor: What Can It Be?. In: Misyurin S., Arakelian V., Avetisyan A. (eds) Advanced Technologies in Robotics and Intelligent Systems. Mechanisms and Machine Science. 2020. Vol 80. Pp. 163-169. Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-33491-8_20

7. Yasnitsky L.N., Dumler A.A., Cherepanov F.M., Yasnitsky V.L., 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. November, 2021 DOI: 10.1080/23808993.2021.1993595.

8. 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. <https://cloud.mail.ru/public/Cj62/Cxa6xf3EL>.

https://www.elibrary.ru/download/elibrary_36727550_41770760.pdf

9. Ясницкий Л.Н. О научном приоритете пермских ученых в области искусственного интеллекта // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. Часть I. Сборник статей по материалам Четвертой всероссийской научно-практической конференции, проводимой в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века». 2019. С. 7-25. <https://cloud.mail.ru/public/qzQE/3CTntPDdo>

WHY MODERN MEDICAL DIAGNOSTIC SYSTEMS OF ARTIFICIAL INTELLIGENCE WORK SO BADLY

Leonid N. Yasnitsky

Perm State National Research University

Bukireva str., 15, Perm, Russia, 614068

HSE University

Str. Studencheskaya, 38, Perm, Russia, 614070

dkshsteinle@edu.hse.ru

yasn@psu.ru

Andrey A. Dumler

Perm State Medical University named after Academician E.A. Wagner

Perm, Russia 614000 Perm Krai, Perm, st. Petropavlovskaya 26

ivan.ivanovskii.2000@mail.ru

An explanation is given of the reasons for the unsuccessful attempts to create and the low accuracy of modern medical diagnostic systems of artificial intelligence.

Keywords: Diagnostics, reasons for failures, Know-How, predicting the progression of diseases, lifestyle, taking medications, neural network.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ДИАГНОСТИКЕ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ НА ОСНОВЕ МИНИМАЛЬНОГО НАБОРА ДАННЫХ

*Жвакин Анатолий Анатольевич¹, Арутюнян Ваграм Борисович²,
Породников Артём Александрович², Наумова Наталья Алексеевна²,
Южакова Ксения Владимировна², Абубакирова Ольга Александровна³,
Степанов Максим Сергеевич⁴*

¹ ООО «Траектория будущего», г. Москва, Батайский проезд, д.43. Помещение 1/1.

² ФГБУ «Федеральный центр сердечно-сосудистой хирургии имени С.Г. Суханова»
Министерства здравоохранения Российской Федерации (г. Пермь),
614013, Россия, г. Пермь, ул. Маршала Жукова, 35.

³ Medion Innovation DIATEC EQUIPMENT SERVICE г. Ташкент

⁴ ГБУЗ ПК Клинический кардиологический диспансер г.Пермь, ул. Сибирская 84.
porodickov.a@yandex.ru

В статье представлено описание правильной подготовки данных для обучения искусственного интеллекта (ИИ), что, в свою очередь, позволит ему на основании жалоб, анамнестических данных, данных лабораторно-инструментальных методов исследований пациента поставить первичный диагноз, акцентируя внимание на сердечно-сосудистой патологии.

Ключевые слова: диагностика заболевания, сердечно-сосудистые заболевания, подготовка данных, обучение нейросети, искусственный интеллект.

Введение. Сердечно-сосудистые заболевания являются основной причиной смерти людей во всем мире: она занимает лидирующее место. По оценкам данных за 2008 год от ССЗ умерло 17.3 миллиона человек, что составило 30% от всех случаев смерти в мире. В 2023 году эта цифра выросла до 18,6 миллионов. К 2030 году, согласно прогнозам экспертов ВОЗ, эта цифра может кардинально вырасти до 23,6 миллионов умерших человек, главным образом, от болезней сердца и инсульта, которые, по прогнозам, останутся основными причинами смерти [1]. Поэтому на эту насущную и прогрессирующую проблему нельзя закрывать глаза. Профилактика заболевания является важным и во многом эффективным способом борьбы с ССЗ, но далеко не каждый человек может ей следовать. Самое эффективное в данной проблеме – это ранняя диагностика патологии и последующее своевременное лечение, сводящее к минимуму развитие осложнений.

Необходимость и преимущество искусственного интеллекта.

Во многих городах Пермского края серьезная недостаточность узкоспециализированных врачей, включая кардиологов, из-за чего оказывается несвоевременная диагностика и помощь [2]. Одним из вариантов решения этой проблемы может стать искусственный интеллект: используя получаемые доктором данные о пациенте и анализируя их, он способен диагностировать сердечно-сосудистую патологию у больного, чем облегчает работу врачей. Искусственный интеллект извлекает знания непосредственно из жизненного опыта, кото-

рый богаче теоретического, поэтому нейросетевые диагнозы нередко оказываются более точными, чем поставленные врачом [3]. Существуют примеры, когда нейронная сеть в диагностическом критерии оказалась эффективней врачей. К такому выводу пришла международная группа ученых из Германии, Франции и США. Результаты исследования опубликованы в журнале *Annals of Oncology*. Специалисты показали ИИ изображения опасных для жизни форм рака кожи и безвредных родинок, чтобы натренировать ИИ в дифференциальной диагностике. Затем фотографии отослали 58 дерматологам из разных стран с различным опытом работы. В результате искусственный интеллект научился лучше врачей различать злокачественные и доброкачественные образования: медикам удалось обнаружить меланомы в 86,6% случаев, тогда как ИИ – в 95% [4]. Это показывает нам то, что искусственный интеллект способна не только запомнить огромное количество информации, но и эффективно ей обучиться и использовать. Такая точность диагностики может позволить спасти большое количество жизней, что значительно повлияет на решение проблемы высокой сердечно-сосудистой смертности.

Источник и правильная подготовка данных (Сбор и анализ данных).

Сбор анамнеза и лабораторно-диагностических данных для обучения ИИ диагностике сердечно-сосудистых патологий будет организовано на базе «Федерального центра сердечно-сосудистой хирургии имени С.Г. Суханова», г. Пермь, где с момента открытия 2012 года было пролечено более 75 тысяч пациентов. Такой огромный ресурс медицинских данных позволит создать крепкий «фундамент опыта» для создания качественной нейросети.

Для обучения ИИ важен не только объем, но и качество данных. Данные должны быть:

1. Полными: отсутствие данных может привести к неверным выводам. Например, отсутствие информации о давлении крови или холестерине может исказить картину здоровья пациента.

2. Консистентными: данные должны быть стандартизированы. Например, измерения давления должны быть приведены к единой системе измерений.

3. Достоверными: данные должны быть точными и правдивыми. Если данные вводятся вручную, вероятность ошибки увеличивается. Автоматизация сбора данных может снизить этот риск.

4. Актуальными: данные должны быть своевременно обновлены. Старые данные могут не отображать текущего состояния здоровья пациента.

Так же необходима предобработка данных. Она включает в себя:

1. Очистку данных: удаление дубликатов, пропусков, аномалий и шумов в данных. Это позволяет избежать искажений в модели.

2. Стандартизацию: приведение данных к единому формату и структуре, что облегчает их обработку и анализ.


3. Аннономность: удаление личной информации для защиты конфиденциальности пациентов, что особенно важно в условиях строгих требований к защите данных.

4. Аргументацию данных: искусственное увеличение объема данных путем создания новых экземпляров на основе уже имеющихся, что помогает избежать проблемы недостатка данных.

Параметры диагностики. У каждой болезни есть свои диагностические «точки опоры» – критерии, на которые опирается врач, выставляя диагноз. В базу искусственного интеллекта это можно ввести как «параметры». Если у меланомы главный параметр – это визуальный осмотр, что является первоначальным диагностическим критерием, то при заболеваниях сердечно-сосудистой системы, таких параметров несколько. Так как не в каждом населенном пункте существует высокоспециализированная диагностика, такая как коронарография, МСКТ, то для определения заболевания необходимо использовать доступные «инструменты». За минимальный набор параметров для выставления диагноза можно взять: X1 – жалобы, X2 – анамнез заболевания, X3 – физикальное обследование, X4 – ЭКГ, X5 – лабораторные методы исследования. Так же, при возможности получения расширенного медицинского обследования пациента, можно добавлять данные различных видов медицинской визуализации: коронарографии, МСКТ, ЭХОКГ; данные с переносных устройств, отслеживающих: физическую активность пациента, пульс, артериальное давление и электрическую активность сердца. Все это позволит искусственному интеллекту максимально точно поставить диагноз пациенту с патологией сердечно-сосудистой системы.

Примеры работы искусственного интеллекта для диагностики ССЗ.

1. Рассмотрим такой клинический синдром как стенокардия, которая может является первым признаком ишемической болезни сердца (ИБС) и способна перейти в острую форму. У таких пациентов имеется характерная загрудинная боль, возникающая при физической и эмоциональной нагрузке, которая может купироваться в покое или после приема нитроглицерина, что отличает это состояние от других заболеваний сердца [5]. Анамнез заболевания так же играет ключевую роль в диагностике, позволяя найти потенциальную причину и проследить ход болезни.




Важность параметра для конкретного состояния.


Каждый такой параметр может иметь разный «вес» в диагностике определенных заболеваний.

2. При нарушениях сердечного ритма показатель ЭКГ будет ключевым для определения патологии. Для примера нарушения проводимости была взята атриовентрикулярная блокада сердца 2 степени типа Мобитц II, на ней про-

грамма считает выпадение участка QRS, при сохранении интервалов PQ, что является критерием данной патологии [6].



Так же нужно проанализировать важность дополнительных параметров, которые можно загрузить в нейросеть. При приобретенных пороках сердца, жалобы и другие параметры могут оказаться полезными для выявления патологии, но при возможности сделать пациенту ЭхоКГ, по которой можно посмотреть структуру сердца, система выдаст более четкий результат.



Митральная недостаточность.

Снимки ЭхоКГ пациента быстро анализируются ИИ, и в совокупности с другими параметрами, она с легкостью определяют стеноз или недостаточность любого клапана сердца.

Данные для каждого параметра загружаются через приложение и анализируются искусственным интеллектом для поиска такой же информации как у пациентов из базы «Федерального центра сердечно-сосудистой хирургии. имени С.Г. Суханова» с подтвержденным диагнозом. Грамотно обученный искусственный интеллект при наличии схожего анамнеза, результатов лабораторно-диагностических исследований пациенту позволит сформулировать первичный диагноз на основе минимального количества данных. Что является немало важным для определения дальнейшей тактики ведения пациента.

Заключение. Проблема прогрессирования сердечно-сосудистых заболеваний в мире продолжает нарастать, и мы должны прибегнуть ко всем возможным вариантам решения этой проблемы. Искусственный интеллект способен обработать огромное количество информации и обучиться распознавать диагнозы. При наличии большой базы данных и структурированной информации о пациентах, искусственный интеллект даст врачу огромные возможности в быстрой и точной диагностике, чтобы своевременно оказать необходимую помощь.

Библиографический список

1. EEE-science.ru – Сайт с исследовательской работой по сердечно-сосудистой заболеваемости. Статистика смертности от ССЗ. [Электронный ресурс]. Режим доступа: <https://eee-science.ru/item-work/2021-2090/>
2. Properm.ru – новостной сайт. [Электронный ресурс]. Режим доступа: <https://properm.ru/news/2023-09-23/net-nevrologa-kardiologa-nehvatka-vrachei-vozmuschaet-zhiteley-permskogo-kрая-3049544>
3. Ясницкий Л.Н., Думлер А.А., Черепанов Ф.М. Новые возможности применения методов искусственного интеллекта для моделирования появления и развития заболеваний и оптимизации их профилактики и лечения. Терапия. 2018; 1(19):109–118
4. Iz.ru – новостной сайт со статьей об исследовании ии для рака кожи. [Электронный ресурс]. Режим доступа: <https://iz.ru/749939/2018-05-30/iskusstvennyi-intellekt-nauchitsia-luchshe-vrachei-vyavliat-rak-kozhi>
5. probolezny.ru– Стенокардия. [Электронный ресурс]. Режим доступа: <https://probolezny.ru/stenokardiya/>
6. 63valentina.ru – презентация про блокады сердца. [Электронный ресурс]. Режим доступа: <https://63valentina.ru/vidiy/blokad/>

ARTIFICIAL INTELLIGENCE IN DIAGNOSTICS OF CARDIOVASCULAR DISEASES BASED ON A MINIMUM SET OF DATA

*Anatoly Zhvakin, Vagram Arutyunyan, Artem Porodikov, Natalya Naumova,
Ksenia Yuzhakova, Olga Abubakirova, Maxim Stepanov*

The article describes the correct preparation of data for training artificial intelligence (AI), which, in turn, will allow it to make a primary diagnosis based on complaints, anamnestic data, laboratory and instrumental research methods of the patient, focusing on cardiovascular pathology.

Key words: disease diagnostics, cardiovascular diseases, data preparation, neural network training, artificial intelligence.

УДК 004.89

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ ГОЛОВНОГО МОЗГА ПАЦИЕНТОВ С НАРУШЕННЫМ СОЗНАНИЕМ

Попов Илларион Евгеньевич

Волгоградский государственный университет,
4000062, Россия, г. Волгоград, пр. Университетский, 100
popov.larion@volsu.ru

Крылова Александра Евгеньевна

Волгоградский государственный университет,
4000062, Россия, г. Волгоград, пр. Университетский, 100
a.krylova@volsu.ru

Скобей Илья Вадимович

Волгоградский государственный университет,
4000062, Россия, г. Волгоград, пр. Университетский, 100
ilya.s.2002@mail.ru

В статье проводится интеллектуальный анализ термометрических данных головного мозга. Найдены информативные признаки, определяющие изменения температурных полей при применении метода краниocereбральной гипотермии на пациентах в вегетативном состоянии и состоянии минимального сознания. Показана возможность применения систем искусственного интеллекта в данной области.

Ключевые слова: микроволновая радиотермометрия, машинное обучение, интеллектуальный анализ данных.

Введение. Микроволновая радиотермометрия (МВР) – метод диагностики заболеваний, при которых происходит изменение температур внутренних тканей. Данный метод позволяет измерять температуры и на поверхности тела и на некоторой глубине, фиксируя излучения биологического тела в разных диапазонах [4]. Наибольшее количество тепла производится внутренними органами, при этом большая часть заболеваний уже на ранних стадиях влияют на температурное поле пораженных ими органов или тканей человеческого тела. На основе данного влияния становится возможной ранняя диагностика заболеваний, и, следовательно, построение систем искусственного интеллекта, выполняющих консультативную роль при постановке диагноза специалистами. За последние годы было создано несколько подобных систем, определяющих различные заболевания [1, 2].

Первым этапом создания систем искусственного интеллекта является построение математической модели, описывающей характеристические особенности различных диагностических классов. Математическая модель состоит из интерпретируемых высокоинформативных признаков, на основе которых строится высокоточная модель классификации, а также возможно обоснование предлагаемого системой искусственного интеллекта диагностического решения. В данной работе исследуются два состояния головного мозга: вегетативное и минимальное сознание. Состояние минимального сознания – это тяжелое нарушение сознания, при котором имеют место минимальные признаки целенаправленного поведения, свидетельствующие об осознании пациентом соб-

ственной личности и окружающей действительности. Вегетативное состояние представляет собой отсутствие реактивности и осознания, связанное с грубым нарушением функции больших полушарий головного мозга. Определение данных состояний по температурным измерениям позволит быстро и эффективно отслеживать эффективность лечения пациентов, а также динамику их выздоровления, на основе чего может корректироваться курс лечения.

Материалы и методы. В данной работе нами была рассмотрена база данных, в которой представлены сведения о больных, получивших травмы головного мозга. В результате обследований были проведены температурные измерения в 18 различных точках у 77 пациентов. На рис. 1 приведена схема измерений для левого полушария, аналогичным образом расположены области измерения на правом. В базе данных представлены пациенты с различными повреждениями, такими как: ишемический и геморрагический инсульт, закрытая и открытая черепно-мозговые травмы, сочетанная травма, аноксическое повреждение и аневризмы головного мозга. Пациенты были разделены на 2 класса: состояние минимального сознания (СМС) и вегетативное состояние (ВС). Диагноз ставится на основе клинических данных. Лечение, главным образом, поддерживающее.

У всех пациентов, представленных в базе данных, измерялись температуры до применения метода краниocereбральной гипотермии (КЦГ) и температуры после проведения терапии этим методом. Метод КЦГ – это метод локальной гипотермии тканей головы и головного мозга, он может применяться неоднократно. В первую очередь перед нами стояла задача понять, есть ли отличие между пациентами до КЦГ и после КЦГ с точки зрения их температурных полей. Если это отличие существует, то в дальнейшем возможно применение методов машинного обучения для прогнозирования динамики изменения состояния пациента. На данный момент мы не можем сразу определить сколько сеансов КЦГ нужно провести больному и насколько они ему помогут. Поэтому подобное прогнозирование позволило бы заранее оценивать количество необходимых для пациента сеансов КЦГ, а также то, насколько поможет этому человеку данная процедура.




Рис. 1. Схема измерений кожных и глубинных температур одного полушария головного мозга пациентов

Признаки. Изначально в базе есть только измерения температур, однако имеет смысл рассматривать точки вместе, как некоторую область, в связи с тем, что воздействие КЦГ не является точечным. Для первого приближения мы ограничились лишь определенным видом областей, которые в дальнейшем будем называть «тройками». Тройка – это область, состоящая из трех точек измерения температур. Множество троек является довольно внушительным, поэтому для начала было принято решение работать с 6-ю конкретными:

- 1) (1, 2, 3)
- 2) (4, 5, 6)
- 3) (7, 8, 9)
- 4) (1, 4, 7)
- 5) (2, 5, 8)
- 6) (3, 6, 9)

Здесь цифры в кортеже обозначают точку измерения, соответствующую точке на схеме измерений, а кортеж – рассматриваемую область. Тройки могут характеризовать как правое, так и левое полушарие.

На основе работы [3] было построено 478 признаков, каждый из которых характеризует различные температурные аномалии, такие как: наличие области повышенных температур, асимметрия температурных полей правого и левого полушария, нарушенный баланс глубинных и кожных температур. Для того, чтобы понять, какие признаки являются определяющими изменения, был проведен их отбор.

В качестве алгоритма отбора признаков использовался модифицированный алгоритм поиска информативных зон, по которым определяется качество отделения объектов одних классов от других.

Так как состояния ВС и СМС достаточно сильно отличаются друг от друга, то для каждого представителя этих классов алгоритм применялся отдельно. По модифицированному алгоритму было построено более 200 информативных интервалов, в табл. 1 и 2 приведено по пять наиболее информативных признаков для пациентов в ВС и СМС соответственно.

Проанализировав наиболее информативные из полученного набора признаков, были получены следующие выводы: для обоих классов верно, что КЦГ изменило разность средних температур в двух разных областях, то есть КЦГ локально повлияло на некоторую область головного мозга. Также об этом свидетельствует возрастание разниц среднеквадратических отклонений по разным областям.

Т.к. изменения коснулись и внутреннего градиента (результат вычитания значения кожной температуры от глубинной), то можно сделать вывод о том, что КЦГ повлияло не только на глубинные, но и на кожные температуры, данный вывод подтверждает и высокая информативность признаков, связанных как с глубинной температурой, так и с кожной.

У класса СМС влияние КЦГ на верхнюю часть головы отличается от влияния на другие области (все признаки так или иначе сравниваются с областью 1 тройки).

Таблица 1

Наиболее информативные признаки для пациентов ВС

Признак	Левая граница интервала	Правая граница интервала	Информативность
Разница средних значений глубинных температур между 4 и 6 тройками правого полушария	0	0,3	8,01
Разница среднеквадратичных отклонений глубинных температур между тройками 1 и 5 левого полушария	-0,2	0,2	7,35
Максимум из средних значений кожных температур в правом полушарии по всем тройкам	34,77	35,17	7,25
Разница средних значений глубинных температур между тройками 2 и 3 правого полушария	-0,3	0,3	6,56
Среднеквадратичное отклонение кожных температур в тройке 6 правого полушария	0	0,8	6,51

Таблица 2

Наиболее информативные признаки для пациентов СМС

Признак	Левая граница интервала	Правая граница интервала	Информативность
Разница среднеквадратичных отклонений кожных температур между тройками 1 и 2 правого полушария	0	1,5	7,41
Аналог вторых производных для температур левого полушария соответствующих троек	0	0,8	7,41
Разница среднеквадратичных отклонений кожных температур между тройками 1 и 5 правого полушария	0	1,2	7,23
Значения градиента левого полушария в точке 1	1,2	3,2	6,75
Разница средних значений глубинных температур между тройками 1 и 5 левого полушария	0	0,3	6,75

Заключение. Таким образом выявленные закономерности в динамике изменения температурных полей позволяют отслеживать эффективность применения метода КЦГ, а также проводить диагностику методами искусственного интеллекта.

Отслеживание изменения температурных полей методами искусственного интеллекта при применении КЦГ позволит прогнозировать темп выздоровление и количество сеансов, необходимых для улучшения состояния пациента.

Диагностика методами искусственного интеллекта позволит проводить дифференциальную диагностику, отделяющую пациентов в вегетативном состоянии от пациентов в состоянии нарушенного сознания.

Библиографический список

1. Веснин, С. Г. Микроволновая радиотермометрия молочных желез: современное состояние и пути совершенствования / С. Г. Веснин, М. К. Седанкин // Нанотехнологии: разработка, применение – XXI век. – 2023. – Т. 15, № 3. – С. 11-22. – DOI 10.18127/j22250980-202303-02.
2. Попов, И. Е. Анализ термометрических данных головного мозга, полученных методом микроволновой радиотермометрии / И. Е. Попов, А. Е. Крылова // Математическая физика и компьютерное моделирование. – 2023. – Т. 26, № 2. – С. 32-42. – DOI 10.15688/mpcm.jvolsu.2023.2.3.
3. Levshinskii, V. V. Multiclass Classification in the Problem of Differential Diagnosis of Venous Diseases Based on Microwave Radiometry Data / V. V. Levshinskii // Program Systems: Theory and Applications. – 2021. – Vol. 12, No. 2(49). – P. 37-52. – DOI 10.25209/2079-3316-2021-12-2-37-52.
4. Research of a Microwave Radiometer for Monitoring of Internal Temperature of Biological Tissues / S. G. Vesnin, M. Sedankin, V. Leushin, V. Skuratov, I. Nelin, A. Kononova // Eastern-European Journal of Enterprise Technologies. – 2019 – Vol. 2086, № 1 – P. 6–15. – DOI: 10.15587/1729-4061.2019.176357

INTELLIGENT ANALYSIS OF THERMOMETRIC DATA FROM THE BRAIN OF PATIENTS WITH IMPAIRED CONSCIOUSNESS

Illarion E. Popov

Volgograd State University,
4000062, Russia, Volgograd, Universitetsky Ave., 100
popov.larion@volsu.ru

Aleksandra E. Krylova

Volgograd State University,
4000062, Russia, Volgograd, Universitetsky Ave., 100
a.krylova@volsu.ru

Ilya V. Skobey

Volgograd State University,
4000062, Russia, Volgograd, Universitetsky Ave., 100
ilya.s.2002@mail.ru

The article presents an intelligent analysis of the brain thermometric data. Informative features are found that determine changes in temperature fields when using the craniocerebral hypothermia method on patients in a vegetative state and in a state of impaired consciousness. The possibility of using artificial intelligence systems in this area is shown.

Key words: microwave radiothermometry, machine learning, data mining.

**ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА «KARDIONET»
В ДИАГНОСТИКЕ ОСТРОГО КОРОНАРНОГО СИНДРОМА
В УСЛОВИЯХ ВЫЕЗДНОЙ БРИГАДЫ СКОРОЙ МЕДИЦИНСКОЙ
ПОМОЩИ: «ПОЛЕВЫЕ ИСПЫТАНИЯ»**

Думлер Андрей Артурович

ФГБОУ ВО «Пермский государственный медицинский университет
имени академика Е.А. Вагнера» Минздрава РФ, Пермь, Россия
614000 Пермский край, г. Пермь, ул. Петропавловская 26
ivan.ivanovskii.2000@mail.ru

Утева Наталья Анатольевна

ФГБОУ ВО «Пермский государственный медицинский университет
имени академика Е.А. Вагнера» Минздрава РФ, Пермь, Россия
614000 Пермский край, г. Пермь, ул. Петропавловская 26
nat.utewa@yandex.ru

Ясницкий Леонид Нахимович

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

В статье описан опыт разработки и применения нейросетевой системы для ранней диагностики острого коронарного синдрома в условиях выездной бригады скорой медицинской помощи. Обнаруженные методом нейросетевого математического моделирования закономерности и следующие из них выводы при их повсеместном внедрении способны оптимизировать выявление данного состояния и ускорить оказание медицинской помощи.

Ключевые слова: система диагностики, острый коронарный синдром, скорая медицинская помощь, нейронная сеть.

Введение. Острый коронарный синдром (ОКС) – термин, обозначающий любую группу признаков и симптомов, позволяющих подозревать инфаркт миокарда (ИМ) или нестабильную стенокардию (НС) с высоким риском развития ИМ [1]. ОКС является непосредственной угрозой жизни пациента и поводом для его немедленной госпитализации. Ежегодно до 2,5 миллионов пациентов в мире госпитализируются с этим диагнозом. В индустриально развитых странах заболеваемость ОКС составляет 6 на 10000 населения [2].

Для обеспечения наилучших результатов лечения очень важны действия, которые будут производиться после первого контакта пациента с сотрудниками, имеющими медицинское образование (врачи и фельдшера скорой помощи, поликлиники) и сроки, в которые эти действия будут производиться [3]. То есть, сотрудники первичного медицинского звена должны быть вооружены технологиями, позволяющими наиболее быстрое выявление ОКС.

Проблема использования искусственного интеллекта в медицине, в частности в кардиологии и, особенно для диагностики ОКС, широко обсуждается в

научной печати. Так в обзорах [4] отмечено, что ИИ посредством машинного обучения продемонстрировал несколько потенциальных преимуществ у пациентов с ОКС. От диагностики до эффектов лечения и прогнозирования неблагоприятных событий и смертности у пациентов с ОКС, машинное обучение должно найти существенное место в клинической медицине и в интервенционной кардиологии для лечения и ведения пациентов с ОКС, в том числе в условиях службы скорой медицинской помощи [5].

Постановка задачи. Для создания системы диагностики ОКС был использован программный ресурс, разработанный учеными ПГНИУ: «Нейросимулятор 5.0» [7]. Нейронные сети были обучены на примерах 1200 пациентов с ОКС, находящихся на лечении в Отделении неотложной кардиологии ГАУЗ ПК ГКБ№4 г.Перми. Диагноз каждого пациента был верифицирован всеми вышеперечисленными методами. В обучающее множество вошли пациенты с ИМ (различных клинических форм и локализаций) и НС.

Демонстрационный прототип интеллектуальной системы диагностики и прогнозирования развития сердечно-сосудистых заболеваний человека, названный KARDIONET размещен на сайте Пермского отделения Научного совета РАН по методологии искусственного интеллекта (www.PermAi.ru) в разделе «Проекты».

Работа с системой осуществляется в три этапа.

На первом этапе запускается нейронная сеть, выполняющая «Самостоятельное обследование» клиента, предназначенная для пользователя, не имеющего медицинского образования. В меню «Общие сведения» и «История жизни» пользователю предлагается ввести 27 параметров, характеризующих его дату рождения, возраст, пол, рост, вес, группу крови, наличие вредных привычек (курение, употребление алкоголя, наркотиков), занятие физкультурой, сведения о ранее перенесенных заболеваниях, сведения о наличии заболеваний у родственников, жалобы и т.д. На основании этих данных система ставит предварительный диагноз в виде гистограммы из семи столбцов, высота каждого из которых отражает вероятность (или степень развития) соответствующего заболевания сердечно-сосудистой системы: инфаркт миокарда, стенокардия стабильная, стенокардия нестабильная, гипертоническая болезнь, аритмии и блокады сердца, хроническая сердечная недостаточность, острая сердечная недостаточность.

На втором этапе с помощью пункта меню: «Первичное обследование» пользователю предлагается ввести дополнительно еще 22 параметра: пальпация пульса, артериальное давление, наличие ожирения, окраска кожных покровов, данные электрокардиографии и т.д., после чего система выставляет уточненный диагноз, учитывающий эти дополнительные сведения.

На третьем этапе с помощью пункта меню «Специальное обследование» пользователю предлагается ввести еще 20 параметров, с результатами эхокардиографии, общего и биохимического анализа крови. Таким образом, окончательный диагноз система выставляет с учетом 69 параметров пациента.

Интеллектуальная система является математической моделью изучаемой предметной области – человека с его комплексом сердечно-сосудистых заболе-

ваний. Поэтому, в пределах математической погрешности, математическая модель ведет себя так же, как вела бы себя сама моделируемая предметная область. Поэтому разработанную математическую модель можно использовать для исследования закономерностей предметной области. Например, изменяя какой-либо один или несколько входных параметров (возраст, вес, привычки и др.) наблюдать за поведением выходных параметров – степенью развития заболеваний.

Этот метод исследования математических моделей называется «методом замораживания», поскольку все остальные входные параметры, характеризующие человека и его состояния здоровья в процессе компьютерного эксперимента, остаются неизменными. Метод замораживания имеет недостаток, заключающийся в том, что в действительности, входные параметры системы обычно имеют между собой сложные корреляционные взаимозависимости, и при изменении одного из входных параметров другие параметры тоже должны быть изменены согласно этим зависимостям. Например, с возрастом появляются новые симптомы, изменения на электрокардиограмме, результаты эхокардиографии и т.д. Но такие зависимости заранее неизвестны. Поэтому, при создании нейросетевых моделей, предназначенных для исследования предметных областей с целью получения новых знаний, рекомендуется [6] использовать минимальное количество входных параметров, оставляя остальные входные параметры «за кадром», т.е. не ограничивая их изменение. Иногда, при умелом подборе минимального количества входных параметров удается добиться относительно высокой точности диагностики. Например, на первом этапе работы предлагаемой интеллектуальной системы, используя только такие первоначальные сведения о пациенте, как дата рождения, возраст, пол, рост, вес, группа крови, наличие вредных привычек, занятие физкультурой, сведения о ранее перенесенных заболеваниях, сведения о наличии заболеваний у родственников, минимальное количество жалоб, нейронные сети прогнозируют вероятность наличия (или степени развития) заболеваний с погрешностью 15 – 20%. Поэтому, для исследования закономерностей моделируемой предметной области были выбраны нейронные сети именно первого этапа предлагаемой интеллектуальной системы.

Результаты собственных исследований («Полевые испытания»). Для решения поставленной цели обследовано 49 человек (38 мужчин и 11 женщин) в возрасте от 42 до 85 лет (средний возраст $61,6 \pm 0,1$ лет). Тестирование пациентов системой KARDIONET проводилось только на первом этапе «Самостоятельное обследование». Все пациенты обратились за помощью в службу Городской станции скорой медицинской помощи г.Пермь по поводу болевого синдрома в грудной клетке или одышки (удушья). Тестирование проводилось фельдшером выездной бригады. Правильность заключения системы была проверена в программе ЕСИЗ «Промед», которая рассматривалась в качестве «золотого стандарта».

Во всех 49 случаях KARDIONET показал высокий риск наличия ССЗ (ИМ и НС). В одном случае KARDIONET не выявил ИМ, однако выставил НС, что не является фатальной ошибкой. В двух случаях KARDIONET отверг ИМ и НС и рекомендовал оставить больного на амбулаторном лечении, что было

подтверждено кардиологом приемного отделения. В одном случае система выявила наличие фатального нарушения ритма сердца, что было подтверждено в отделении хирургической аритмологии. В последующем, по данным ЕСИЗ «Промед», все пациенты были доставлены в кардиологические отделения г. Пермь. Из них у 35 пациентов диагностирован ОКС (больные экстренно госпитализированы), у шести пациентов – неосложненный гипертонический криз, после оказания помощи эти больные были отпущены на амбулаторное лечение. Чувствительность метода составила 88%, специфичность 89%.

Вывод. Нейросетевая система KARDIONET в режиме «Самостоятельное обследование», доступном для применения пользователю интернета даже без специальной подготовки, способна достаточно эффективно выявлять ССЗ, прежде всего в их тяжелой форме (ОКС) и может быть использована в работе первичного звена здравоохранения.

Библиографический список

1. Кардиология: национальное руководство/ под ред. Ю.Н.Беленкова, Р.Г.Оганова. – М.: ГЭОТАР-Медиа, 2011. – 1232 с.
2. Приказ МЗ РФ от 01.07.2015 405 ан .
3. 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. 7(2): BM-095-15, 8 pages. (http://www.biolmedonline.com/Articles/Vol7_2_2015/BM-095-15_Artificial-Neural-Networks-for-Obtaining-New-Medical-Knowledge-Diagnostics-and-Prediction-of-Cardiovascular-Disease-Progr.pdf).
4. Hong Yan et all. Application of Artificial Intelligence in Acute Coronary Syndrome: A Brief Literature Review // Adv Ther. 2021 Oct;38(10):5078-5086. doi: 10.1007/s12325-021-01908-2. Epub 2021 Sep 15.
5. Brianna Mueller et all/ Artificial intelligence and machine learning in emergency medicine: a narrative review // Acute Med Surg // 2022 Mar 1;9(1):e740. doi: 10.1002/ams2.740. eCollection 2022 Jan-Dec.
6. Yasnitsky L.N., Dumler A.A., Bogdanov K.V., Poleschuk A.N., Cherepanov F.M., Makurina T.V., Chugaynov S.V. Diagnosis and Prognosis of Cardiovascular Diseases on the Basis of Neural Networks // Biomedical Engineering. 2013. Vol. 47. No 3. Pp. 160-163. DOI: 10.1007/s10527-013-9359-0.
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 4.0. Свидетельство о регистрации программы для ЭВМ RUS 2014612546. Заявка № 2014610341 от 15.01.2014.

INTELLIGENT SYSTEM "KARDIONET" IN DIAGNOSTICS OF ACUTE CORONARY SYNDROME IN CONDITIONS OF A MOBILE EMERGENCY TEAM: "FIELD TESTS"

Andrey A. Dumler

Perm State Medical University named after Academician E.A. Wagner
Perm, Russia 614000 Perm Krai, Perm, st. Petropavlovskaya 26
ivan.ivanovskii.2000@mail.ru

Natalia A. Uteva

Perm State Medical University named after Academician E.A. Wagner
Perm, Russia 614000 Perm Krai, Perm, Petropavlovskaya 26
nat.utewa@yandex.ru

Leonid N. Yasnitsky

Perm State National Research University
Bukireva str., 15, Perm, Russia, 614068 HSE University
Str. Studencheskaya, 38, Perm, Russia, 614070
dkshteinle@edu.hse.ru
yasn@psu.ru

The article describes the experience of developing and using a neural network system for early diagnosis of acute coronary syndrome, which is one of the main problems of modern medicine in the conditions of a mobile ambulance team. The patterns discovered by the method of mathematical modeling and the conclusions that follow from them, when implemented everywhere, are capable of optimizing the detection of this condition and accelerating the provision of medical care.

Keywords: diagnostic system, acute coronary syndrome, emergency medical care, neural network.

Научное издание

**Искусственный интеллект в решении
актуальных социальных и экономических проблем XXI века**

Сборник статей по материалам Девятой всероссийской
научно-практической конференции с международным участием

(г. Пермь, ПГНИУ, 17–18 октября 2024 г.)

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

Часть 1

Издается в авторской редакции
Компьютерная вёрстка: *Л. Н. Ясницкий, М. А. Радионова*

Подписано в печать 10.12.2024. Формат 60×84/16.
Усл. печ. л. 19,35. Тираж 100 экз. Заказ 147

Управление издательской деятельности
Пермского государственного
национального исследовательского университета.
614068 г. Пермь, ул. Букирева, 15

Отпечатано в полиграфическом отделе
614068 г. Пермь, ул. Букирева, 15
Тел.: (342) 239-65-47

