МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ФГБОУ ВО «ДОНЕЦКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ»
ПРЕДСТАВИТЕЛЬСТВО РАН НА ТЕРРИТОРИИ ДНР

ISSN 2664-7362 (PRINT)
ISSN 2664-7370 (ONLINE)

МАТЕРИАЛЫ
XI Международной научной конференции

Донецкие чтения – 2026:
образование, наука, инновации, культура и вызовы современности



Том 2 | **Физические, технические и компьютерные науки. Часть 2**

Министерство науки и высшего образования
Российской Федерации

Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Донецкий государственный университет»

Представительство федерального государственного
бюджетного учреждения «Российская академия наук»
на территории Донецкой Народной Республики

XI Международная научная конференция

Материалы конференции

Донецкие чтения – 2026:

образование, наука, инновации, культура и вызовы современности

Том 2

ФИЗИЧЕСКИЕ, ТЕХНИЧЕСКИЕ И КОМПЬЮТЕРНЫЕ НАУКИ

Часть 2

г. Донецк
10–12 ноября 2026 г.

Донецк
Издательство ДонГУ
2026

ББК В3я431+397я431
УДК 53+62+004(043.2)
Д672

Редакционная коллегия:

С.В. Беспалова (гл. ред.), А.В. Белый (зам. гл. ред.),
М.В. Фоменко, С.А. Фоменко, И.А. Третьяков (отв. секр. секции),
В.К. Толстых, А.Г. Петренко, Е.Д. Пометун.

Д672 **Донецкие чтения – 2026: образование, наука, инновации, культура и вызовы современности:** Материалы XI Международной научной конференции (Донецк, 10–12 ноября 2026 г.). – *Том 2: Физические, технические и компьютерные науки Часть 2* / под общей редакцией проф. С.В. Беспаловой. – Донецк: Изд-во ДонГУ, 2026. – 247 с.

Ответственность за содержание материалов, аутентичность цитат, правильность фактов и ссылок несут авторы.

Во второй том материалов XI Международной научной конференции «Донецкие чтения – 2026: образование, наука, инновации, культура и вызовы современности» вошли исследования по актуальным проблемам физических, технических и компьютерных наук. Рассматриваются вопросы физической гидроаэродинамики, метрологии, техносферной безопасности, теоретической и экспериментальной физики, радиофизики, инфокоммуникационных технологий, информационной безопасности, компьютерных систем и технологий искусственного интеллекта.

Освещенные в сборнике проблемы и направления их решения будут полезны научным работникам, преподавателям, студентам, аспирантам и докторантам, проводящим исследования в области физических, технических и компьютерных наук.

ББК В3я431++397я431
УДК 53+62+004(043.2)

© Коллектив авторов, 2026
© Донецкий государственный университет, 2026

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель:

Панченко Владислав Яковлевич, вице-президент Российской академии наук, д-р физ.-мат. наук, профессор, академик РАН (г. Москва).

Сопредседатель:

Беспалова Светлана Владимировна, ректор Донецкого государственного университета, руководитель Представительства Российской академии наук на территории Донецкой Народной Республики, д-р физ.-мат. наук, профессор (г. Донецк).

Члены программного комитета:

Алексеев Игорь Александрович, ведущий научный сотрудник лаборатории физической географии и биогеографии Института географии им. В. Б. Сочавы СО РАН, д-р геогр. наук (г. Иркутск).

Андреев Дмитрий Александрович, заместитель декана по научной работе исторического факультета Московского государственного университета имени М. В. Ломоносова (г. Москва), д-р ист. наук, доцент (г. Москва).

Аноприенко Александр Яковлевич, ректор Донецкого национального технического университета, канд. техн. наук, профессор (г. Донецк).

Бабурин Сергей Николаевич, президент Ассоциации юридических вузов, научный руководитель Центра интеграционных и цивилизационных исследований Института государства и права РАН, д-р юрид. наук, профессор, почётный профессор Донецкого государственного университета (г. Москва).

Бахтин Станислав Геннадиевич, декан химического факультета Донецкого государственного университета, канд. хим. наук, доцент (г. Донецк).

Белозеров Геннадий Александрович, заместитель генерального директора Автономной некоммерческой организации «Агентство стратегических инициатив по продвижению новых проектов».

Белый Александр Владимирович, проректор по научной и инновационной деятельности Донецкого государственного университета, канд. хим. наук, доцент (г. Донецк).

Блинова Елена Евгеньевна, заведующая кафедрой прикладной психологии и развития личности Херсонского государственного педагогического университета, д-р психол. наук, профессор (г. Херсон).

Вартанова Елена Леонидовна, декан факультета журналистики Московского государственного университета имени М. В. Ломоносова, д-р филол. наук, академик РАО (г. Москва).

Варюхин Виктор Николаевич, научный руководитель Донецкого физико-технического института им. А. А. Галкина, д-р физ. мат. наук, профессор, член-корр. РАН, (г. Донецк).

Воронова Ольга Евгеньевна, профессор кафедры литературы и журналистики, руководитель Центра региональных проектов и межрегиональных связей Рязанского государственного университета имени С. А. Есенина, д-р филол. наук, профессор (г. Рязань).

Ганиева Ирина Александровна, директор АНО «Научно образовательный центр „Кузбасс“», д-р экон. наук, доцент (г. Кемерово).

Глухов Александр Захарович, главный научный сотрудник Донецкого ботанического сада, профессор кафедры ботаники и экологии Донецкого государственного университета, д-р биол. наук, профессор (г. Донецк).

Головчан Алексей Витальевич, директор Донецкого физико-технического института им. А. А. Галкина, канд. физ. мат. наук, доцент (г. Донецк).

Данилюк Даниил Анатольевич, и. о. директора Института прикладной математики и механики, канд. физ. мат. наук (г. Донецк).

Журавлёва Екатерина Васильевна, Советник президента РАН, советник Председателя Совета директоров ГК «ЭФКО», д-р с.-х. наук, профессор РАН (г. Белгород).

Зенченко Светлана Вячеславовна, проректор по научной работе Северо-Кавказского федерального университета, д-р экон. наук, профессор (г. Ставрополь).

Зинченко Юрий Петрович, декан факультета психологии Московского государственного университета имени М. В. Ломоносова, д-р психол. наук, профессор, член-корреспондент РАН, академик РАО (г. Москва).

Игнатенко Григорий Анатольевич, ректор Донецкого государственного медицинского университета им. М. Горького, д-р мед. наук, профессор, академик РАН (г. Донецк).

Ильинский Владимир Викторович, и. о. зав. кафедрой общей экологии и гидробиологии Московского государственного университета имени М. В. Ломоносова, д-р биол. наук, профессор (г. Москва).

Исаков Владимир Борисович, профессор НИУ «Высшая школа экономики», д-р юрид. наук, профессор (г. Москва).

Калмыков Степан Николаевич, вице-президент Российской академии наук, д-р хим. наук, профессор, академик РАН (г. Москва).

Керимов Александр Джангирович, главный научный сотрудник Института государства и права Российской академии наук, д-р юрид. наук, профессор (г. Москва).

Кирпичников Михаил Петрович, декан биологического факультета Московского государственного университета имени М. В. Ломоносова, д-р биол. наук, профессор, академик РАН (г. Москва).

Кожухов Игорь Борисович, профессор кафедры высшей математики НИУ «Московский институт электронной техники», д-р физ. мат. наук, профессор (г. Москва).

Крамаренко Артём Александрович, заместитель Председателя Правительства Донецкой Народной Республики, Министр сельского хозяйства, пищевой и перерабатывающей промышленности (г. Донецк).

Красильников Павел Владимирович, декан факультета почвоведения Московского государственного университета имени М. В. Ломоносова, д-р биол. наук, член-корреспондент РАН (г. Москва).

Липгарт Андрей Александрович, декан филологического факультета Московского государственного университета имени М. В. Ломоносова, д-р филол. наук, профессор (г. Москва).

Лубков Алексей Владимирович, ректор Московского педагогического государственного университета, д-р ист. наук, профессор, академик РАО (г. Москва).

Макаров Кирилл Борисович, заместитель Председателя Правительства Донецкой Народной Республики (г. Донецк).

Матишов Геннадий Григорьевич, заместитель президента РАН, научный руководитель Южного научного центра РАН, д-р геогр.наук, профессор, академик РАН (г. Ростов-на-Дону).

Месхи Бесарион Чохоевич, ректор Донского государственного технического университета, председатель Совета ректоров вузов Ростовской области, д-р техн. наук, профессор, академик РАО (г. Ростов на Дону).

Минаев Андрей Иванович, профессор Рязанского государственного университета имени С. А. Есенина, д-р ист. наук, доцент (г. Рязань).

Некипелов Александр Дмитриевич, директор Московской школы экономики Московского государственного университета имени М. В. Ломоносова, д-р экон. наук, профессор, академик РАН (г. Москва).

Нечаев Владимир Дмитриевич, ректор Севастопольского государственного университета, д-р полит. наук, доцент (г. Севастополь).

Овечко Сергей Викторович, заместитель Института биологии южных морей имени А. О. Ковалевского РАН, канд. биол. наук (г. Севастополь).

Пармон Валентин Николаевич, научный руководитель Института катализа СО РАН, д-р хим. наук, академик РАН (г. Новосибирск).

Плугатарь Юрий Владимирович, директор Ордена Трудового Красного Знамени Никитского ботанического сада – Национального научного центра РАН, председатель Совета ботанических садов России, д-р с.-х. наук, профессор, академик РАН (г. Ялта).

Половян Алексей Владимирович, директор Института экономических исследований, д-р экон. наук, доцент, (г. Донецк).

Понедельников Алексей Борисович, руководитель отдела «Северо-Азовский» Южного филиала ФГБНУ «ВНИРО» (г. Мариуполь).

Приходько Светлана Анатольевна, директор Донецкого ботанического сада, канд. биол. наук, ст. науч. сотр. (г. Донецк).

Прутцков Григорий Владимирович, профессор Института медиа НИУ «Высшая школа экономики», д-р филол. наук (г. Москва).

Рябичев Виктор Дронович, ректор Луганского государственного университета имени Владимира Даля, д-р техн. наук, профессор (г. Луганск).

Садовничий Виктор Антонович, ректор Московского государственного университета имени М. В. Ломоносова, д-р физ.-мат. наук, профессор, академик РАН (г. Москва).

Секиринский Дмитрий Сергеевич, заместитель Министра науки и высшего образования Российской Федерации.

Скуратовская Екатерина Николаевна, врио директора Института биологии южных морей имени А. О. Ковалевского РАН, канд. биол. наук (г. Севастополь).

Сократов Сергей Альфредович, зам. декана географического факультета Московского государственного университета имени М. В. Ломоносова, канд. геогр. наук, доцент (г. Москва).

Тедеев Вадим Ботазович, ректор Юго Осетинского государственного университета имени А. А. Тибилова, канд. техн. наук, профессор (г. Цхинвал).

Тохтарь Валерий Константинович, директор Ботанического сада Белгородского государственного национального исследовательского университета, д-р биол. наук, с. н. с. (г. Белгород).

Трофимов Олег Владимирович, Министр образования и науки Донецкой Народной Республики (г. Донецк).

Тулупов Владимир Васильевич, декан факультета журналистики Воронежского государственного университета, д-р филол. наук, профессор (г. Воронеж).

Туранина Неонила Альфредовна, зав. кафедрой библиотечно-информационной деятельности Белгородского государственного института искусств и культуры, д-р филол. наук, профессор (г. Белгород).

Федянин Андрей Анатольевич, проректор – начальник управления научной политики Московского государственного университета им. М. В. Ломоносова, д-р физ. мат. наук, профессор, член-корреспондент РАН (г. Москва).

Харламенкова Наталья Евгеньевна, заведующая лабораторией психологии развития субъекта в нормальных и посттравматических состояниях, заместитель директора Института психологии РАН, д-р психол. наук, профессор (г. Москва).

Хомутова Екатерина Валерьевна, директор Института физико-органической химии и углехимии им. Л. М. Литвиненко, канд. биол. наук (г. Донецк).

Шебалков Алексей Викторович, Министр природных ресурсов и экологии Донецкой Народной Республики (г. Донецк).

Компьютерные системы и технологии искусственного интеллекта

УДК 004.932:004.94

ПРИМЕНЕНИЕ ИИ-АЛГОРИТМОВ УЛУЧШЕНИЯ КАЧЕСТВА ИЗОБРАЖЕНИЯ В СИСТЕМАХ КОМПЬЮТЕРНОГО ЗРЕНИЯ

Абилхан А.С., ORCID 0009-0004-1367-2209,
Косенко О.В., канд. техн. наук, доц., ORCID 0000-0001-5920-6343
ФГАОУ ВО «Южный федеральный университет», г. Таганрог, РФ
abilkhan@sfedu.ru, ovkosenko@sfedu.ru

Системы компьютерного зрения имеют широкое применение в ADAS, однако точность распознавания объектов критически зависит от информативности входного видеопотока. Низкое разрешение камеры, шумы при плохом освещении, размытия от движения, погодные влияния и артефакты сжатия уменьшают информативность дорожной сцены. Наиболее уязвимыми становятся пешеходы, велосипедисты и транспортные средства при разрешении 640x360 пикселей пешеход на расстоянии около 100 м может занимать область лишь 5x12 пикселей.

Традиционные методы улучшения изображения не решают проблему, а лишь увеличивают картину. Поэтому в работе рассматривается восстановление необходимых признаков объектов, необходимых для нейросети. Для данной задачи была выбрана генеративная модель Real-ESRGAN [1], обученная на сложной базе данных с реальными деградациями.

При сравнении вариантов супер-разрешения учитывались качество детализации и высокая отказоустойчивость для бортовой обработки. Модель RealESRGAN_x4plus дает высокую детализацию, но при четырёхкратном улучшении наблюдается слишком медленная работа – порядка 0,6 кадр/с. Следующая исследованная облегченная модель anime_6B работает заметно быстрее, но ориентирована на рисованную графику и сглаживает дорожные текстуры. Самая компактная модель RealESR-General-x4v3 на основе архитектуры SRVGGNetCompact оказалась очень сбалансированной. При двукратном улучшении нейросеть подчеркивает границы объектов и обеспечивает стабильной плавностью видеопотока ориентировочно 30-60 кадр/с, в связи с чем была выбрана в качестве модуля ИИ-улучшения перед подачей в идентификатор YOLOv8n.

Разрабатываемый метод улучшения видеопотока является последовательным, где сначала кадр низкого разрешения поступает в генеративную сеть Real-ESRGAN для улучшения, а затем восстановленное изображение передается в идентификатор YOLOv8n, который формирует

якорные рамки, классы и оценки уверенности [2]. Выбор модели YOLOv8n обоснован из-за одноэтапной архитектуры, высокой скорости вывода, а компактный генератор удерживает задержку в пределах режима, близкого к реальному времени. В благоприятных условиях улучшение можно отключать, а в случае наступления ночи или осадков применять более аккуратный режим.

В целях того, чтобы изображение не превращалось в набор красивых текстур, в методе применяется обратная связь Detection-Oriented Perceptual Loss. Данная функция сравнивает не только пиксели, но и промежуточные признаки YOLOv8n для восстановленного и эталонного изображений. Берутся выходы блоков C2f уровней P3, P4 и P5 с размерностями 128, 256 и 512 каналов. Составная ошибка генератора записывается по следующим формулам:

$$L_{\Sigma} = \lambda_{pix} \cdot L_{pix} + \lambda_{per} \cdot L_{per} + \lambda_{adv} \cdot L_{adv} + \lambda_{d} \cdot L_{DOPL}, \qquad (1)$$

$$L_{\mathrm{DOPL}} = \sum_{k} MSE(F_{YOLO}^{(k)}(I_{SR}), F_{YOLO}^{(k)}(I_{HR})), \qquad (2)$$

где I_{SR} – восстановленное изображение, I_{HR} – эталонное изображение, $F_{YOLO}^{(k)}$ – карта признаков -го уровня идентификатора. Данная методика относится к Task-Driven Super-Resolution, когда генератор специализируется на обучении ради повышения точности последующего распознавания объектов [3].

Практический результат работы данного метода представлен на рисунке.



Рис. Сравнение идентификации объектов до и после ИИ-улучшения изображения

На левом изображении приведен пример стандартной работы идентификатора YOLOv8n в условиях низкого разрешения видеопотока. Можно заметить, что мелкие объекты не идентифицируются или получают нестабильные якорные рамки. Изображение справа показывает тот же кадр, но после обработки в разрабатываемом конвейере Real-ESRGAN в связке с YOLOv8n. При анализе важны появившиеся рамки, их положение, уверенность идентификации и уменьшение ложных срабатываний при бликах, тенях и шуме.

Проверка метода выполняется на дорожных сценах, записанных в условиях дня, ночи и погодных осадках. Изображения искусственно ухудшаются путем уменьшения разрешения, добавления размытия, шума, зернистости и сжатия. Сравниваются обычный YOLOv8n после

бикубического масштабирования, последовательный Real-ESRGAN и YOLOv9n, а также версия с дообучением при Detection-Oriented Perceptual Loss. Используются метрики PSNR, SSIM, Precision Recall, F1, mAP@0.5, mAP@0.5:0.95 и FPS.

Главный смысл применения Real-ESRGAN в рамках адаптивной системы помощи водителю ADAS заключается в том, чтобы вернуть идентификатору опорные признаки, как: края блок-фар, контуры кузова автомобиля, силуэты пешеходов. При двукратном улучшении область пешехода условно увеличивается с 5x12 до 10x24 пикселей. Физически новой информации не возникает, но генератор восстанавливает более выраженную форму, которую модель YOLO уже способна отличить от фона.

Функция обратной связи Detection-Oriented Perceptual Loss в исследуемой системе используется как дополнительный ограничитель, поскольку штрафует генератор Real-ESRGAN за расхождение в признаковом пространстве идентификатора. В дальнейшем режим обработки можно выбирать исходя из дорожной сцены. Для примера: систему можно настроить так, чтобы днем использовался экономичный режим, стандартный при умеренной деградации, а более ресурсный ночью или в случае осадков.

Рассматривая подсистему автоматического управления светотехникой автомобиля ADAS важно оперативно идентифицировать встречный транспорт, пешеходов, велосипедистов в моментах, когда их признаки занимают несколько десятков пикселей. Правила ЕЭК ОНН № 48 задают требования к внешним световым приборам, поэтому устойчивость идентификации напрямую связана с безопасностью и позволяет точнее переключать световой режим.

В данной работе обоснован гибридный подход использования моделей Real-ESRGAN и YOLOv8n для повышения надежности компьютерного зрения при низком качестве изображения. Real-ESRGAN рассматривается не как универсальный инструмент повышения уровня детализации, а как модуль восстановления признаков, необходимых идентификатору. В ходе исследования было выявлено, что RealESRGeneral-x4v3 дает приемлемый баланс между качеством и скоростью. Detection-Oriented Perceptual Loss дополнительно связывает обучение генератора с задачей идентификации.

Список литературы

1. Wang X. Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic Data / X. Wang, L. Xie, C. Dong [et al.] // 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). – Piscataway: IEEE, 2021. – P. 1905-1914. – DOI 10.1109/ICCVW54120.2021.00217.
2. Jocher G. Ultralytics YOLOv8: computer software / G. Jocher, A. Chaurasia, J. Qiu. – 2023. – URL: https://github.com/ultralytics/ultralytics (дата обращения: 25.09.2026).
3. Haris, G. Shakhnarovich, N. Ukita // Neural Information Processing: 28th International Conference, ICONIP 2021. – Cham: Springer, 2021. – P. 387-395.

УДК 303.732.4:53.08:303.224:536.71

ОБ ОЦЕНКЕ ЭФФЕКТИВНОСТИ ПРОЦЕССОВ РАЗВИТИЯ ЕСТЕСТВЕННЫХ СИСТЕМ

Аверин Г.В., д-р техн. наук, проф., ORCID 0000-0003-1070-3677,
Звягинцева А.В., д-р техн. наук, доц., ORCID 0000-0003-2218-9230,
Бражников А.Р., ORCID 0009-0005-4420-9206
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
g.averin@donnu.ru, zviagintsevaav@gmail.com, yanox123321@gmail.com

Введение. В современных исследованиях сложных систем процессы развития рассматриваются как нелинейные, многомерные и многомасштабные изменения состояния, структуры, связей и функций системы, происходящие во времени и пространстве. В данной работе под развитием естественной системы (природной, социальной, биологической, природно-урбанизированной и т.д.) будем понимать закономерное, необратимое и, как правило, нелинейное изменение её состояний, характеризующихся совокупностью параметров, которые подлежат контролю или статистическому учету. Такое развитие может включать как прогрессивные, так и регрессивные изменения, фазовые переходы и бифуркации, поэтому его оценка требует многокритериальной и контекстно-зависимой системы показателей.

В системных, социально-экономических, экологических и технических исследованиях используются представления об эволюционном, ускоренном, устойчивом, сбалансированном, безопасном, кризисном, прогрессивном, деградационном, целенаправленном, интенсивном и других типах развития. Однако многие из характеристик этих типов развития остаются качественными, нормативно ориентированными и имеющими отраслевую специфику. Современная теория развития систем, включая системную динамику, синергетику, теорию сложности, эволюционную кибернетику и концепции устойчивого развития, предлагает формализовать процессы развития через динамические модели, критерии устойчивости, адаптивности, эмерджентности, жизнеспособности и эффективности.

Под эффективностью процесса развития естественной системы будем понимать многомерную меру соответствия динамики её состояния заданным критериям, учитывающим значимость, масштабность, ценность, полезность и т.п. изменений в направлениях, которые определяют цели, результаты и уровни соответствующего типа развития. Несмотря на наличие отдельных теорий и моделей, единая общепризнанная теория развития естественных систем ещё не построена, что определяет актуальность настоящей работы.

Постановка проблемы. В современной науке отсутствует единая концептуальная и теоретико-методологическая база оценки эффективности

процессов развития сложных систем. Существующие представления об эволюционном, устойчивом, безопасном, прогрессивном и т.п. развитии носят описательный и субъективный характер, слабо формализованы и не позволяют сопоставлять разнородные естественные системы по единым критериям [1–4]. Это затрудняет обоснование стратегий развития, прогнозирование последствий и принятие решений в условиях нелинейной динамики, неопределённости и ограниченности ресурсов.

Цель работы – разработать концептуальные основы оценки эффективности процессов развития естественных систем применительно к многомерным динамическим пространствам их состояний, которые позволят анализировать процессы развития как траектории движения систем по отношению к эталонным траекториям, принятым по соглашению.

Основная часть. Идея работы состоит в том, что на основе опытных данных можно получить феноменологическое описание коллективного развития (поведения, деятельности, функционирования) однородных объектов в виде векторных или статистических моделей [4]. Решение поставленной задачи основывается на следующих гипотезах: класс изучаемых объектов рассматривается как гомогенная система, которая образована множеством однородных объектов, имеющих единую природу и общий набор признаков; многомерное пространство состояний системы относительно признаков (переменных состояния z_k) является континуальным, каждой точке континуума (каждому состоянию) ставится в соответствие **число**, которое интерпретируется как момент времени, поле времени можно записать как скалярную функцию переменных состояния: $t=t(z_1,z_2,..,z_n)$; феноменологическая модель пространства состояний может быть построена по опытным данным и описана средствами векторного анализа или дифференциальной геометрии; каждому объекту в пространстве состояний соответствует своя траектория развития; для каждой точки M любой траектории может быть сформирован n-мерный вектор текущего положения относительно начальной точки M_0 этой траектории; в пространстве состояний может быть задана эталонная траектория развития реального или гипотетического объекта (группы объектов), которая удовлетворяет некоторым стандартам, нормам, правилам, ретроспективным данным, пороговым значениям, достижимым результатам, допустимым или фоновым уровням и т.д.; сравнение траектории развития объекта возможно по отношению к эталонной траектории; существуют многомерные критерии (функции состояния), которые по своему содержанию могут выступать интегральными (комплексными) мерами процессов развития системы и на основе которых возможно провести ранжирование объектов.

Эталонная траектория за определенный интервал времени будет определять выбранную тенденцию развития или характеризовать

наилучшие результаты. В зависимости от того какие условия будут заданы при формировании траектории, можно при попарном сравнении говорить о прогрессивном, деградационном, безопасном, целенаправленном развитии, которое относится к эволюционному развитию объектов. В случае, если речь будет идти об устойчивом или сбалансированном развитии, то эталонную траекторию необходимо сформировать, исходя из научно-обоснованных пропорций устойчивости или сбалансированности процессов развития для изучаемого класса объектов. Модель континуального пространства состояний предполагает существование для системы направлений наибольшей скорости процесса развития (градиента), когда процесс обладает максимальной длиной многомерной траектории за заданный интервал времени. В этом случае можно говорить об ускоренном или интенсивном развитии. Методика построения подобных моделей и прикладные примеры анализа систем приведены в работах [4–7].

Заключение. Таким образом, предлагается концептуальный подход к оценке эффективности развития естественных систем, основанный на попарном сравнении траекторий движения объектов в многомерном пространстве состояний. Подход опирается на гипотезы гомогенности объектов, континуальности пространства состояний и возможности формирования интегральных многомерных критериев. Это позволяет различать прогрессивное, деградационное, устойчивое, сбалансированное и интенсивное развитие, а также ранжировать объекты с учетом результатов функционирования или деятельности.

Список литературы

1. Preiser, R. Social-ecological systems as complex adaptive systems: organizing principles for advancing research methods and approaches / R. Preiser, R. Biggs, A. De Vos [et al.] // Ecology and Society. – 2018. – Vol. 23(4). – P. 46. – DOI 10.5751/ES-10558-230446.
2. Urban, J. B. The Systems Evaluation Protocol for evaluation planning / J. B. Urban, M. Hargraves, J. Buckley [et al.] // New Directions for Evaluation – 2021. – P. 31–45. – DOI 10.1002/ev.20443.
3. Ginevičius, R. Evaluating the sustained development of socio-economic systems / R. Ginevičius // Economics and Sociology. 2024. – Vol. 17(4). – P. 315-332. – DOI 10.14254/2071 789X.2024/17-4/17.
4. Аверин, Г. В. Векторные и статистические критерии относительной сложности при сравнении объектов по совокупности параметров / Г. В. Аверин, А. В. Звягинцева, А. Р. Бражников // Проблемы искусственного интеллекта. – 2026. – № 1(40). – С. 124–136. – DOI 10.24412/2413-7383-2026-1-40-124-136. – EDN LYWTHQ.
5. Аверин Г. В. Системодинамика: теория и приложения / Изд. 2-е перераб. и доп. Донецк: ООО «НПП «Фолиант», 2022. – 535 с. ISBN 978-5-6047945-0-0. EDN LJDBFI.
6. Звягинцева А. В. Вероятностные методы комплексной оценки природно-антропогенных систем / Под науч. ред. Г.В. Аверина. – М.: Изд. дом «Спектр», 2016. – 257 с. ISBN 978-5-4442-0120-6.
7. Аверин Г. В. Основы темпорологии / Г. В. Аверин – Донецк: ООО «НПП «Фолиант», 2024. – 310 с. ISBN 978-5-6050291-4-4.

УДК 004.8:621.311

ИНТЕЛЛЕКТУАЛЬНОЕ УПРАВЛЕНИЕ НАКОПИТЕЛЯМИ ЭНЕРГИИ В ЦЕНТРАХ ОБРАБОТКИ ДАННЫХ: ОТ РЕЗЕРВНОГО ПИТАНИЯ К ПРОГНОЗНОМУ СРЕЗАНИЮ ПИКОВОЙ НАГРУЗКИ

Алджаф Ш.М.А., ORCID 0000-0002-2182-0759
ФГАОУ ВО «Южный федеральный университет», г. Таганрог, РФ
saldzhaf@sfedu.ru

Введение. Центры обработки данных (ЦОД) относятся к наиболее быстро растущим потребителям электроэнергии: по оценке Международного энергетического агентства, в 2024 г. на их долю пришлось около 415 ТВт·ч, или примерно 1,5 % мирового электропотребления, а к 2030 г. потребление может более чем удвоиться, до порядка 945 ТВт·ч [1]. Для оператора ЦОД важна и пиковая мощность: от неё зависят текущие расходы на электроэнергию и капитальные затраты на инфраструктуру электропитания [2]. При этом практически каждый ЦОД уже располагает запасом энергии в виде аккумуляторных батарей систем бесперебойного питания (ИБП). Они предназначены для перехода на резервный источник при отказе внешней сети и большую часть времени не используются [2]. В работе проанализированы подходы к использованию этого запаса для управления пиковой нагрузкой и сформулированы требования к интеллектуальной системе управления накопителем.

Использование накопленной энергии для срезания пиков. В работе [2] предложено рассматривать батареи ИБП как энергетический буфер: заряжать их в периоды низкого потребления и разряжать в часы пиков. Поскольку частые разряды сокращают срок службы батарей и уменьшают резерв на случай аварии, авторы определили допустимые режимы работы с учётом этих ограничений и в эксперименте получили снижение пиковой мощности на 15–45 %, что соответствовало сокращению текущих затрат на 6–18 %. В работе [3] рассмотрена распределённая архитектура с ИБП на уровне отдельного сервера: энергия накапливается в периоды низкой активности и расходуется при всплесках потребления, что позволило срезать 19,4 % пиковой мощности без потери производительности, разместить на 24 % больше серверов в том же бюджете мощности и снизить совокупную стоимость владения в расчёте на сервер на 6,3 %. В работе [4] показано, что модели, не учитывающие физические характеристики батарей, переоценивают их срок службы в 2,4 раза. Предложенное там распределённое управление батареями отличается от централизованного по сроку службы не более чем на 3,3 % при десятикратном снижении затрат на обмен данными. Сопоставление подходов приведено в таблице.

Таблица

Подходы к использованию накопителей ЦОД для срезания пиков

Работа	**Размещение накопителя**	**Основной результат**	**Главное ограничение**
[2]	Централизованные ИБП	Снижение пика на 15–45 %, затрат на 6–18 %	Ресурс батарей и резерв на случай аварии
[3]	ИБП на уровне сервера	Срезание 19,4 % пика, +24 % серверов	Длительность доступной энергии
[4]	Распределённое управление батареями	Срок службы в пределах 3,3 % от централизованного	Точность модели деградации

Из таблицы видно, что все три подхода используют одну и ту же схему «заряд в провалах, разряд в пиках», но различаются уровнем размещения накопителя и способом управления. Централизованная схема [2] проще в управлении, но оперирует одним агрегированным запасом энергии. Распределённые схемы [3, 4] позволяют срезать пики на уровне отдельных серверов и стоек, однако требуют согласования решений множества локальных контроллеров и точной оценки состояния каждой батареи. Для системы управления это означает необходимость иерархической структуры: локальные контроллеры реагируют на кратковременные всплески потребления, а верхний уровень распределяет между ними доступный запас энергии с учётом прогноза нагрузки и ограничений на резерв.

Конфликт целей и роль прогнозирования. Во всех рассмотренных работах решение о разряде накопителя в текущий момент зависит от того, ожидается ли позже более высокий пик: энергия, израсходованная преждевременно, недоступна в момент максимальной нагрузки и одновременно уменьшает резерв. Тот же накопитель может служить ресурсом управления спросом энергосистемы и облегчать интеграцию возобновляемых источников [5], что добавляет к внутренней задаче ЦОД внешние ценовые сигналы. Поэтому управление накопителем требует прогнозирования собственной нагрузки ЦОД и цен на электроэнергию. Для прогнозирования цен автором предложена гибридная модель LSTM-Transformer с остаточным обучением [6].

Требования к интеллектуальной системе управления. На основе анализа можно сформулировать следующие требования: 1) горизонт прогноза нагрузки и цен должен охватывать расчётный период, в котором фиксируется пиковая мощность; 2) модель деградации батарей должна учитывать их физические характеристики, иначе экономия завышается [4]; 3) неснижаемый уровень заряда, необходимый для резервирования, должен входить в модель как жёсткое ограничение [2]; 4) решения о разряде накопителя должны согласовываться с планированием вычислительной нагрузки, поскольку перенос откладываемых задач и

разряд батарей решают одну и ту же задачу снижения пика. Последнее требование естественно реализуется в мультиагентной архитектуре, где прогнозирование, планирование нагрузки и управление накопителем выполняются взаимодействующими агентами [7].

Заключение. Накопители энергии, установленные в ЦОД для резервирования, представляют собой уже оплаченный ресурс управления пиковой нагрузкой. Известные подходы снижают пиковую мощность и затраты, но их эффективность ограничена ресурсом батарей, необходимостью сохранять резерв и неопределённостью будущей нагрузки. Преодоление этих ограничений связано с применением методов искусственного интеллекта: прогнозирования нагрузки и цен, моделей деградации батарей и согласованного планирования работы накопителя и вычислительной нагрузки.

Список литературы

1. Energy and AI: World Energy Outlook Special Report / International Energy Agency. – Paris: IEA, 2025. – URL: https://www.iea.org/reports/energy-and-ai (дата обращения: 04.10.2026). – Текст: электронный.
2. Govindan, S. Benefits and limitations of tapping into stored energy for datacenters / S. Govindan, A. Sivasubramaniam, B. Urgaonkar // Proceedings of the 38th Annual International Symposium on Computer Architecture (ISCA). – New York: ACM, 2011. – P. 341–352. – DOI 10.1145/2000064.2000105.
3. Kontorinis V. Managing distributed UPS energy for effective power capping in data centers / V. Kontorinis, L. E. Zhang, B. Aksanli [et al.] // 39th Annual International Symposium on Computer Architecture (ISCA). – IEEE, 2012. – P. 488–499. – DOI 10.1109/ISCA.2012.6237042.
4. Aksanli, B. Distributed battery control for peak power shaving in datacenters / B. Aksanli, T. Rosing, E. Pettis // 2013 International Green Computing Conference (IGCC). – IEEE, 2013. – P. 1–8. – DOI 10.1109/IGCC.2013.6604477.
5. Wierman A. Opportunities and challenges for data center demand response / A. Wierman, Z. Liu, I. Liu, H. Mohsenian-Rad // 2014 International Green Computing Conference (IGCC). – IEEE, 2014. – P. 1–10. – DOI 10.1109/IGCC.2014.7039172.
6. Алджаф, Ш. М. А. Гибридная модель LSTM-Transformer с остаточным обучением для прогнозирования цен оптового рынка электроэнергии в задаче управления нагрузкой центров обработки данных / Ш. М. А. Алджаф; науч. рук. Ю. А. Кравченко // Современные информационные технологии в условиях новых вызовов: материалы IX Междунар. науч. конф., 20 мая 2026 г. – Донецк: ФГБОУ ВО «ДОННУЭТ», 2026. – С. 210–212.
7. Алджаф, Ш. М. А. Мультиагентная архитектура интеллектуального управления нагрузкой географически распределённых центров обработки данных / Ш. М. А. Алджаф, Ю. А. Кравченко // Безопасность. Управление. Искусственный интеллект. – 2026. – Т. 5, № S5. – С. 111–116. – EDN TTVUCG.

УДК 004.032.26

ЭКСТРЕМАЛЬНАЯ ОБУЧАЮЩАЯ МАШИНА (ELM): АРХИТЕКТУРА И НЕИТЕРАЦИОННЫЙ АЛГОРИТМ ОБУЧЕНИЯ

Аль-Текрети А.А., ORCID 0009-0007-2808-9595
ФГАОУ ВО «Южный федеральный университет», г. Таганрог, РФ
altekreti@sfedu.ru,

Введение. Градиентные алгоритмы обучения нейронных сетей прямого распространения, включая метод обратного распространения ошибки, сходятся медленно, чувствительны к шуму в данных и могут попадать в локальные минимумы [1]. Альтернативой служит экстремальная обучающая машина (Extreme Learning Machine, ELM) алгоритм обучения сети с одним скрытым слоем, в котором входные веса и смещения скрытого слоя задаются случайно и не настраиваются, а выходные веса вычисляются аналитически [2, 3]. ELM сходится намного быстрее традиционных методов [2]; развиты её регуляризованная и многослойная формы [4], а теория метода в последние годы уточняется [5].

Цель работы изложить архитектуру и математическую модель ELM и показать, почему её обучение не требует итераций.

Основная часть. *Архитектура.* ELM содержит n входных нейронов по числу признаков вектора $\mathbf{x}$, L скрытых нейронов с нелинейной функцией активации g (например, сигмоидной) и m выходных нейронов, соответствующих при классификации классам; на рис. показан случай одного выхода [3, 6]. Входные веса $\mathbf{w}_i$ и смещения b_i генерируются случайно (например, из интервала $[-1, 1]$) и далее не изменяются; обучаются только выходные веса $\boldsymbol{\beta}_i$ [3].

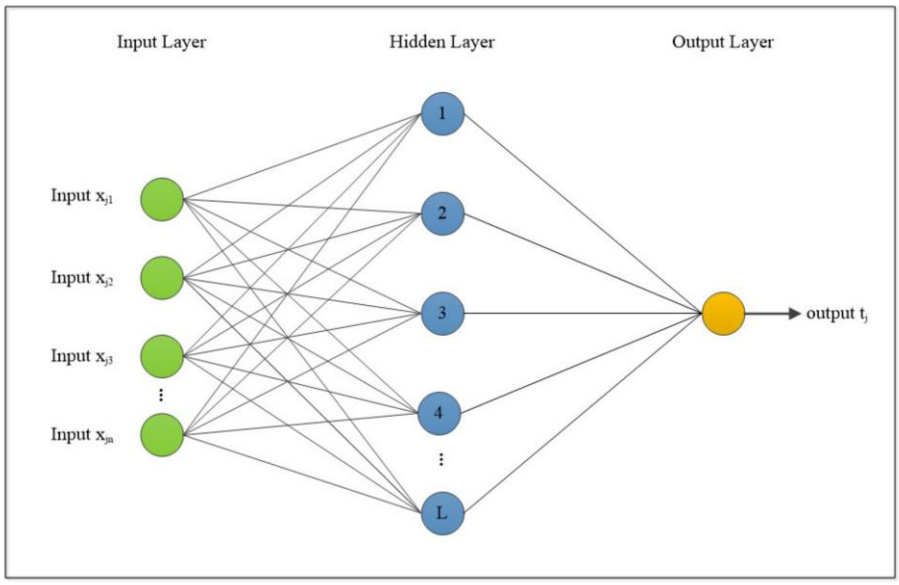


Рис. Схема ELM [6]

Выход сети для входного вектора **x** имеет вид [3, 4, 6]

$$\mathbf{f}_L(\mathbf{x}) = \sum_{i=1}^{L} \boldsymbol{\beta}_i \; g(\mathbf{w}_i \cdot \mathbf{x} + b_i) = \mathbf{h}(\mathbf{x})\,\boldsymbol{\beta} \tag{1}$$

где $\mathbf{h}(\mathbf{x}) = [g(\mathbf{w}_1 \cdot \mathbf{x} + b_1), \ldots, g(\mathbf{w}_L \cdot \mathbf{x} + b_L)]$ – выход скрытого слоя, т. е. случайное нелинейное отображение входа в L-мерное пространство признаков [4]; $\boldsymbol{\beta}$ – матрица выходных весов размера $L \times m$.

Матричная модель. Условия $\mathbf{f}_L(\mathbf{x}_j) = \mathbf{t}_j$ для N примеров дают систему

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}, \qquad \mathbf{H} = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \cdots & g(\mathbf{w}_L \cdot \mathbf{x}_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \cdots & g(\mathbf{w}_L \cdot \mathbf{x}_N + b_L) \end{bmatrix}_{N \times L} \tag{2}$$

где $\mathbf{T} = [\mathbf{t}_1, \ldots, \mathbf{t}_N]^{\mathrm{T}}$; i-й столбец выходной матрицы скрытого слоя **H** содержит отклики i-го нейрона на все примеры [3, 6]. Поскольку $\mathbf{w}_i$, b_i фиксированы, **H** вычисляется один раз и задача становится линейной по $\boldsymbol{\beta}$ [6].

Традиционно утверждается, что при $L = N$ матрица **H** с вероятностью единица обратима, а для любого $\varepsilon > 0$ найдётся $L \le N$ с погрешностью обучения меньше ε [5]; доказана и универсальная аппроксимирующая способность такой сети [4]. Однако в [5] показано, что исходные доказательства двух первых утверждений нестроги, и построен набор данных, на котором даже при $L = N$ выходы сети далеки от обучающих значений; в уточнённой формулировке вероятность получить необратимую **H** равна нулю при непрерывно дифференцируемой g со счётным числом критических точек и линейно независимых входных векторах [5].

Аналитическое обучение. Обычно $L < N$, и выходные веса находят как решение задачи наименьших квадратов [3, 6]:

$$\widehat{\boldsymbol{\beta}} = \mathbf{H}^{\dagger}\mathbf{T}, \qquad \left\|\mathbf{H}\widehat{\boldsymbol{\beta}} - \mathbf{T}\right\| = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \tag{3}$$

где $\mathbf{H}^{\dagger}$ – обобщённая обратная матрица Мура – Пенроуза (при невырожденной $\mathbf{H}^{\mathrm{T}}\mathbf{H}$ она равна $(\mathbf{H}^{\mathrm{T}}\mathbf{H})^{-1}\mathbf{H}^{\mathrm{T}}$), а $\mathbf{H}^{\dagger}\mathbf{T}$ – решение наименьших квадратов с наименьшей нормой. Выходные веса получаются без итераций и подбора скорости обучения [3, 6].

Итак, обучение ELM включает три шага [3]: случайное задание $\mathbf{w}_i$, b_i; вычисление **H**; вычисление выходных весов по (3). Выборка обрабатывается за один проход (по нашей оценке, порядка $NLn + NL^2 + L^3$ операций), а градиентное обучение повторяет проходы заранее неизвестное число эпох и может застревать в локальном минимуме [2, 4].

Регуляризация. Минимизируя полусумму квадрата нормы выходных весов и квадратичной ошибки с весом $C > 0$, получают [4]

$$\boldsymbol{\beta} = \mathbf{H}^{\mathrm{T}}\left(\frac{\mathbf{I}}{C} + \mathbf{H}\mathbf{H}^{\mathrm{T}}\right)^{-1}\mathbf{T} \quad \text{или} \quad \boldsymbol{\beta} = \left(\frac{\mathbf{I}}{C} + \mathbf{H}^{\mathrm{T}}\mathbf{H}\right)^{-1}\mathbf{H}^{\mathrm{T}}\mathbf{T} \tag{4}$$

где **I** единичная матрица; первая формула требует обращения матрицы $N \times N$, вторая – $L \times L$, поэтому при большом N удобнее вторая.

Ограничения и развитие. Без явного способа выбора входных весов и смещений обученная ELM может оказаться в локальном минимуме, и пригодность модели не гарантируется; эту слабость устраняют сочетанием ELM с методами оптимизации, находящими лучшие веса [6]. Например, в генетическом алгоритме хромосома кодирует все входные веса и смещения (её длина $(n + 1)L$), а приспособленность оценивается по среднеквадратичной ошибке обученной ELM [3]. В многослойной ELM скрытые слои строятся автокодировщиками ELM без итеративной тонкой настройки [1, 4], что сокращает время обучения по сравнению с традиционным глубоким обучением с дней или часов до минут или секунд [4].

Заключение. В ELM нелинейная часть сети (скрытый слой) задаётся случайно, а линейная (выходные веса) вычисляется аналитически, поэтому обучение сводится к однократному решению (3) или (4) без выбора скорости обучения и числа эпох. Однако результат зависит от случайной инициализации, а строгие условия обратимости $\mathbf{H}$ уже, чем считалось ранее [5]; поэтому авторы планируют исследовать направленный выбор параметров скрытого слоя, например генетическим алгоритмом [3, 6].

Список литературы

1. Kaur, R. Multilayer extreme learning machine: a systematic review / R. Kaur, R. K. Roul, S. Batra // Multimedia Tools and Applications. – 2023. – Vol. 82, № 26. – P. 40269–40307. – DOI 10.1007/s11042-023-14634-4.
2. Wang J. A review on extreme learning machine / J. Wang, S. Lu, S.-H. Wang, Y.-D. Zhang // Multimedia Tools and Applications. – 2022. – Vol. 81, № 29. – P. 41611–41660. – DOI 10.1007/s11042-021-11007-7.
3. Albadr M. A. A. Optimised genetic algorithm-extreme learning machine approach for automatic COVID-19 detection / M. A. A. Albadr, S. Tiun, M. Ayob [et al.] // PLoS ONE. – 2020. – Vol. 15, № 12. – Art. e0242899. – DOI 10.1371/journal.pone.0242899.
4. Zhang J. Non-iterative and fast deep learning: multilayer extreme learning machines / J. Zhang, Y. Li, W. Xiao, Z. Zhang // Journal of the Franklin Institute. – 2020. – Vol. 357, № 13. – P. 8925–8955. – DOI 10.1016/j.jfranklin.2020.04.033.
5. Perfilieva I. A critical analysis of the theoretical framework of the Extreme Learning Machine / I. Perfilieva, N. Madrid, M. Ojeda-Aciego [et al.] // Neurocomputing. – 2025. – Vol. 621. – Art. 129298. – DOI 10.1016/j.neucom.2024.129298.
6. Albadr M. A. Genetic algorithm based on natural selection theory for optimization problems / M. A. Albadr, S. Tiun, M. Ayob, F. AL-Dhief // Symmetry. – 2020. – Vol. 12, № 11. – Art. 1758. – DOI 10.3390/sym12111758.

УДК 004.032.26:004.896:004.2

УНИВЕРСАЛЬНЫЙ НЕЙРОВЫЧИСЛИТЕЛЬ ДЛЯ МОБИЛЬНЫХ РОБОТИЗИРОВАННЫХ ПЛАТФОРМ: КОНЦЕПЦИЯ, ТРЕБОВАНИЯ И АРХИТЕКТУРА

Андриян И.В., ORCID 0009-0004-3906-3743,
Андриян О.В., ORCID 0009-0005-2211-2251
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
andriyaniv@yandex.ru, 1_solnishko@mail.ru

Введение. Автономное функционирование мобильных роботов предполагает решение комплекса задач в реальном времени: обнаружение и классификация объектов, семантическая сегментация, SLAM, сенсорная фузия, планирование пути и управление приводами. Традиционная схема, при которой сенсорные данные передаются в облако или на удалённый сервер, имеет принципиальные ограничения: задержка канала связи, зависимость от внешней инфраструктуры, риски нарушения информационной безопасности и высокая нагрузка на радиоканал. Возникает потребность в бортовых нейровычислителях – компактных, энергоэффективных и производительных устройствах, выполняющих нейросетевые вычисления непосредственно на роботе.

Цель работы – систематизация требований к бортовым нейровычислителям и описание концепции универсального устройства, ориентированного на широкий класс мобильных роботизированных платформ.

Основная часть. К бортовому нейровычислителю предъявляются следующие основные требования.

Производительность. Высокая скорость операций с плавающей запятой и тензорных вычислений, измеряемая в TOPS. Для современных задач компьютерного зрения и навигации целевой диапазон – от единиц до десятков TOPS при поддержке форматов FP32, FP16 и INT8.

Энергоэффективность. Энергопотребление от нескольких ватт до десятков ватт. Критичным является показатель TOPS/Вт, поскольку мобильные платформы часто имеют батарейное питание.

Массогабаритные параметры. Малые габариты и масса, позволяющие размещать вычислитель на подвижной платформе без существенного снижения полезной нагрузки.

Задержка. Минимальное время обработки данных для контуров управления реального времени, поддержка детерминированности и жёсткого реального времени.

Устойчивость к внешним воздействиям. Вибрации, удары, пыль, влага, перепады температур, электромагнитные помехи.

Универсальность. Поддержка различных фреймворков (PyTorch, TensorFlow, ONNX), моделей и типов задач; абстрагирование от конкретного аппаратного ускорителя.

Интерфейсы. Ethernet, CAN/CAN FD, UART, SPI, I2C, USB, PCIe, MIPI CSI-2, GPIO – для подключения камер, лидаров, IMU, GPS, приводов и прочей периферии.

Программная совместимость. Поддержка ROS/ROS 2 [4], библиотек машинного обучения, средств оптимизации и отладки.

Информационная безопасность. Защищённая загрузка, разграничение доступа, шифрование каналов обмена, возможность работы в изолированном контуре.

Архитектура универсального нейровычислителя распадается на два неравнозначных пласта – аппаратный и программный, и именно их сопряжение определяет, насколько устройство окажется пригодным для реальной робототехники.

Аппаратная часть. Центральное место занимает CPU: именно на него ложится общая логика работы устройства, обслуживание периферии и запуск операционной системы. Тут стоит выделить NPU – специализированный узел, ориентированный на инференс нейросетей и выигрывающий за счёт низкого энергопотребления при больших объёмах однотипных вычислений. Параллельные расчёты, работа с изображениями, а также обучение и дообучение моделей – это уже задача GPU. Если же возникает необходимость в нестандартных операторах или предварительной обработке сигналов, подключается FPGA: её главное преимущество – возможность перенастройки под конкретную задачу. Помимо этих четырёх блоков, в состав входят оперативная память (с достаточным объёмом и пропускной способностью), энергонезависимая память под ОС, модели, данные и журналы, набор интерфейсов ввода-вывода для сенсоров и исполнительных устройств, а также подсистема питания и охлаждения с защитой от перегрева.

Такой набор компонентов позволяет удерживать баланс между производительностью, энергопотреблением и гибкостью. На практике это выглядит так: массовый инференс разумнее отдавать NPU, параллельные вычисления и обучение – GPU, а адаптацию под особенности конкретной платформы – FPGA.

Программная часть задействует целый стек. Начинается он с операционной системы – это может быть Ubuntu или Yocto на базе Linux, RTOS для жёсткого реального времени либо Linux с патчем PREEMPT_RT. Далее идёт middleware ROS/ROS 2, отвечающий за обмен сообщениями между модулями [4]. Для глубокого обучения используются PyTorch, TensorFlow и ONNX Runtime [5], для ускорения инференса – TensorRT, OpenVINO и TVM [6, 7]. Компьютерное зрение и обработку облаков точек закрывают OpenCV и PCL. Замыкают список инструменты

разработки и отладки: компиляторы, профайлеры, системы логирования и средства трассировки ROS 2.

Универсальность устройства складывается из нескольких факторов. Во-первых, это работа с открытыми форматами моделей, и в первую очередь с ONNX [5]. Во-вторых – абстрагирование от конкретного аппаратного ускорителя через промежуточный слой исполнения. В-третьих – модульное построение, при котором вычислительные блоки и интерфейсы можно заменять. В-четвёртых – возможность переконфигурации под разные классы роботов: от наземных AMR до БПЛА и подводных аппаратов. И наконец, контейнеризация прикладного ПО в сочетании с унифицированными драйверами.

Универсальный нейровычислитель может использоваться в складских и логистических роботах (AMR), беспилотных автомобилях и шаттлах, дронах и БПЛА, сервисных роботах, сельскохозяйственной технике, роботах для спасательных операций, автономных подводных аппаратах. В каждом случае устройство обеспечивает детекцию и классификацию объектов, сегментацию сцен, SLAM и навигацию, сенсорную фузию, планирование пути, управление приводами и человеко-машинное взаимодействие.

Заключение. В работе систематизированы требования к бортовым нейровычислителям для мобильных роботизированных платформ и предложена концепция универсального устройства на основе гетерогенной архитектуры CPU + NPU + GPU + FPGA. Показано, что универсальность обеспечивается поддержкой открытых форматов моделей, абстрагированием от аппаратного ускорителя, модульностью и возможностью переконфигурации. Дальнейшие исследования целесообразно направить на разработку аппаратно-программного прототипа, оценку производительности в задачах SLAM и компьютерного зрения, а также на анализ энергоэффективности и отказоустойчивости в реальных условиях эксплуатации.

Список литературы

1. NVIDIA Jetson: официальный сайт. – URL: https://www.nvidia.com/en-us/autonomous-machines/embedded-systems/ (дата обращения: 01.10.2026). – Текст: электронный.
2. Google Coral: официальный сайт. – URL: https://coral.ai/ (дата обращения: 01.10.2026). – Текст: электронный.
3. Intel Neural Compute Stick 2: официальный сайт. – URL: https://www.intel.com/ (дата обращения: 01.10.2026). – Текст: электронный.
4. ROS 2 Documentation. – URL: https://docs.ros.org/ (дата обращения: 01.10.2026). – Текст: электронный.
5. ONNX. Open Neural Network Exchange. – URL: https://onnx.ai/ (дата обращения: 01.10.2026). – Текст: электронный.
6. TensorRT. NVIDIA Developer. – URL: https://developer.nvidia.com/tensorrt (дата обращения: 01.10.2026). – Текст: электронный.
7. OpenVINO Toolkit. Intel. – URL: https://docs.openvino.ai/ (дата обращения: 01.10.2026). – Текст: электронный.

УДК 004.42

АНАЛИЗ ПРОБЛЕМ МНОГОПОТОЧНОСТИ И ПРИМЕРЫ ИХ РЕШЕНИЯ

***Анкудинов К.А.*[1],** ORCID 0009-0006-0499-709X,
***Саиег Т.Х.*[1],** канд. физ.-мат. наук, доц., ORCID 0000-0003-1394-0379,
***Литвин Д.Б.*[2],** канд. техн. наук, доц., ORCID 0000-0002-6643-8983
[1]Технологический институт сервиса (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Ставрополе, г. Ставрополь, РФ
[2]ФГАОУ ВО «Северо-Кавказский федеральный университет», г. Ставрополь, РФ
barre.barnz1725@gmail.com, dr.timor@mail.ru, Litvin-372@yandex.ru

Введение. Производительность процессоров давно растёт не за счёт тактовой частоты, а за счёт числа ядер, поэтому программа, которой нужна скорость, вынуждена выполнять работу в нескольких потоках. Платой за это становится недетерминированность: порядок, в котором чередуются операции разных потоков, выбирает планировщик операционной системы, и от запуска к запуску он меняется. Зависящая от этого порядка ошибка проявляется редко и может исчезать под отладчиком, поэтому её поиск обходится дорого. Средства работы с потоками описаны в учебной литературе по разным языкам и платформам [1–3], однако сведения о типовых ошибках рассредоточены по источникам.

Цель работы – систематизировать типовые ошибки многопоточных программ по причинам их возникновения и сопоставить каждой из них проверенные способы устранения.

Основная часть. Рассмотрим четыре группы проблем на примере языка C++ [5]; итог анализа сведён в таблицу.

Таблица

Типовые проблемы многопоточности и способы их устранения

Проблема	Причина	Способ устранения
Гонка данных	одновременный доступ к памяти, при котором хотя бы один поток пишет	мьютекс; атомарная переменная
Нарушение порядка видимости	перестановка операций, слабая модель памяти платформы	атомарная переменная, учёт модели памяти
Взаимная блокировка	выполнение четырёх условий Коффмана	единый порядок захвата; захват с ограничением времени; захват всех ресурсов сразу
Потеря производительности	долгая операция внутри критической секции	сокращение критической секции

Гонка данных возникает, когда два потока одновременно обращаются к одной ячейке памяти и хотя бы один из них её изменяет. Простейший пример – увеличение общего счётчика оператором counter++.

Для процессора это три действия: прочитать значение, прибавить единицу, записать результат. Если оба потока прочитают старое значение раньше, чем любой из них выполнит запись, одно из двух увеличений пропадёт. Итог окажется меньше ожидаемого.

Защититься можно двумя способами. Мьютекс превращает участок кода в критическую секцию, которую в каждый момент выполняет только один поток. Средство универсальное, но ожидающие потоки простаивают, а переключение контекста отнимает время. Если защитить нужно единственную переменную, достаточно объявить её атомарной (в C++ – тип std::atomic). Тогда операция выполняется аппаратно как неделимая: на x86 – командой lock xadd, на ARM – парой команд LDREX/STREX, и блокировать поток не требуется [6].

Нарушение порядка видимости. Даже без одновременной записи потоки могут увидеть изменения не в том порядке, в котором они стоят в исходном тексте. Компилятор переставляет независимые операции, процессор исполняет команды вне очереди и накапливает записи в буфере, а кэши ядер согласуются с задержкой. Пусть поток A записывает данные и затем устанавливает флаг ready, а поток B ждёт флага и читает данные. На x86 с его строгой моделью памяти такая схема, как правило, работает. На ARM флаг может стать виден раньше данных, и поток B прочитает неинициализированное значение [6]. Следовательно, о корректности нельзя судить только по исходному тексту: нужно учитывать модель памяти целевой платформы, а флаг передавать через атомарную переменную.

Взаимная блокировка. Потоки останавливаются навсегда, если каждый ждёт ресурс, занятый другим: поток A захватил мьютекс M1 и ждёт M2, а поток B удерживает M2 и ждёт M1 [3, 4]. Для этого должны одновременно выполняться четыре условия, сформулированные Э. Коффманом с соавторами: взаимное исключение, удержание ресурса во время ожидания, невозможность принудительно отобрать ресурс и циклическое ожидание [7]. Достаточно нарушить любое из них.

Чаще всего устраняют циклическое ожидание: каждому мьютексу присваивают числовой ранг и захватывают мьютексы только по возрастанию рангов. Второй способ – захват с ограничением времени (функция try_lock_for): не дождавшись, поток освобождает уже занятые ресурсы и повторяет попытку позже. Третий способ – получать все нужные блокировки одной операцией, например через общий мьютекс для группы ресурсов; тогда исчезает удержание с ожиданием.

Потеря производительности. Слишком широкая критическая секция лишает многопоточность смысла. Если под блокировкой выполняется долгая операция (дисковый или сетевой обмен, объёмный расчёт), остальные потоки выстраиваются в очередь, и программа фактически работает последовательно. Характерный пример – буферизованная запись в СУБД, когда под одной блокировкой находятся и

изменение буфера, и его сброс на диск: под нагрузкой потоки ждут друг друга всё время дисковой операции. Исправление состоит в том, чтобы под блокировкой только подменять заполненный буфер пустым, а запись на диск выполнять уже вне критической секции. По той же причине в мобильных приложениях долгие операции выносят из главного потока в фоновые [2].

Заключение. Рассмотренные ошибки имеют общий источник: программист рассуждает о программе как о последовательности шагов, а аппаратура исполняет её параллельно и переупорядочивает операции. Все четыре рассмотренные проблемы – следствия этого расхождения. Поэтому надёжность параллельной программы определяется прежде всего проектными решениями: сокращением разделяемого состояния, единым порядком захвата блокировок, короткими критическими секциями и применением готовых, проверенных примитивов синхронизации.

Список литературы

1. Биллиг, В. А. Параллельные вычисления и многопоточное программирование: учебник / В. А. Биллиг. – 4-е изд. – Москва: Интернет-Университет Информационных Технологий (ИНТУИТ), Ай Пи Ар Медиа, 2025. – 310 с. – ISBN 978-5-4497-0936-3.
2. Березовская Ю. В. Введение в разработку приложений для ОС Android: учебное пособие / Ю. В. Березовская, О. А. Юфрякова, В. Г. Вологдина [и др.]. – 4-е изд. – Москва: Интернет-Университет Информационных Технологий (ИНТУИТ), Ай Пи Ар Медиа, 2025. – 427 с. – ISBN 978-5-4497-0890-8.
3. Вязовик, Н. А. Программирование на Java: учебное пособие / Н. А. Вязовик. – 4-е изд. – Москва: Интернет-Университет Информационных Технологий (ИНТУИТ), Ай Пи Ар Медиа, 2025. – 601 с. – ISBN 978-5-4497-0852-6.
4. Пржиялковский, В. В. Введение в Oracle SQL: учебное пособие / В. В. Пржиялковский. – 5-е изд. – Москва: Интернет-Университет Информационных Технологий (ИНТУИТ), Ай Пи Ар Медиа, 2026. – 336 с. – ISBN 978-5-4497-1636-1.
5. Гурьянов Л. В. Структурное программирование на C++: учебное пособие / Л. В. Гурьянов, Л. С. Гурьянова, Е. В. Гришин [и др.]. – Москва: Ай Пи Ар Медиа, 2026. – 94 с. – ISBN 978-5-4497-4875-1.
6. Уильямс, Э. Параллельное программирование на C++ в действии. Практика разработки многопоточных программ / Э. Уильямс; пер. с англ. А. А. Слинкина. – Москва: ДМК Пресс, 2012. – 671 с. – ISBN 978-5-94074-448-1.
7. Coffman, E. G. System Deadlocks / E. G. Coffman, M. J. Elphick, A. Shoshani // ACM Computing Surveys. – 1971. – Vol. 3, No. 2. – P. 67–78. – DOI 10.1145/356586.356588.

УДК 004.415.2:004.031.2

БЮДЖЕТ ВЫЧИСЛИТЕЛЬНЫХ РЕСУРСОВ ПОДСИСТЕМЫ МОНИТОРИНГА РЕАЛЬНОГО ВРЕМЕНИ

Ахмадиев А.К., ***Юдина А.В.,***
Гибадуллин Р.Ф., канд. техн. наук, доц.
ФГБОУ ВО «Казанский национальный исследовательский технический университет – Казанский авиационный институт им. А. Н. Туполева», г. Казань, РФ
AkhmadievAnK@stud.kai.ru, annyudina04@yandex.ru, RuslanGibadullin@vk.com

Введение. Раздел мониторинга диагностического приложения отображает в реальном времени температуры, загрузку процессора и памяти, обороты вентилятора, состояние аккумулятора. Особенность такой подсистемы в том, что она потребляет тот же ресурс, который измеряет. Приложение работает постоянно, конкурируя за процессорное время с прикладными задачами, в том числе ресурсоёмкими – обработкой изображений [1] и нейросетевым выводом [2], а на ноутбуке частые пробуждения процессора мешают переходу в глубокие состояния сна и сокращают время автономной работы. При этом период опроса обычно выбирается по впечатлению плавности, хотя требования к нагрузке и к точности разнонаправлены.

Цель работы – построить модель бюджета вычислительных ресурсов подсистемы мониторинга, связывающую период опроса, стоимость обращения к датчику и частоту обновления интерфейса с долей процессорного времени, и получить условие совместимости ограничения на эту долю с требованием к точности отслеживания быстрых изменений показаний.

Основная часть. Нагрузка мониторинга складывается из системных вызовов чтения псевдофайлов hwmon и procfs, запуска внешних утилит, разбора и агрегации показаний, обновления модели данных и перерисовки интерфейса, а также пробуждений процессора по таймерам. Запуск утилиты стоит около 30 мс процессорного времени, тогда как чтение атрибута через файловый дескриптор, открытый однократно при инициализации, – около 15 мкс. Привилегированные показатели (SMART) запрашиваются у отдельной службы, перечень запросов которой образует границу защищённости [3].

Показатели разделяются на группы по допустимому периоду обновления. Пусть группа g содержит n_g показателей, опрашиваемых с периодом T_g при стоимости τ_g на показатель, $\tau_к$ – стоимость обновления интерфейса, f_{ui} – его частота. Тогда доля процессорного времени одного ядра и проектное ограничение имеют вид

$$\rho = \Sigma_g \, n_g \tau_g / \, T_g + \tau_к f_{ui} \le \rho_{доп}, \qquad (1)$$

где $\rho_{\text{доп}} = 2\ \%$ одного ядра – уровень, при котором нагрузка неразличима на двухъядерной конфигурации массового сегмента. Распределение бюджета приведено в таблице 1.

Таблица 1

Распределение бюджета процессорного времени по группам показателей

Группа (состав)	Период	Стоимость	Вклад, %
Быстрая (температуры, загрузка, вентилятор)	0,25–4 с	12 × 15 мкс	0,015
Средняя (ОЗУ, накопители, аккумулятор)	5 с	6 × 40 мкс	0,005
Медленная (SMART, устройства и порты)	300 с	8 × 20 мс	0,053
Отображение (видимые карточки)	2 Гц	1,2 мс	0,240
Итого	–	–	0,313

Запас относительно $\rho_{\text{доп}}$ более чем шестикратный; реализация на трёх внешних утилитах с полной перерисовкой страницы потребляет 13 % ядра.

Сверху период опроса ограничен точностью. Зашумлённые показания сглаживаются экспоненциальным фильтром $y_k = \alpha x_k + (1 - \alpha) y_{k-1}$; полное запаздывание отображения складывается из периода опроса и групповой задержки фильтра, а ошибка на фронте со скоростью v не должна превышать $\varepsilon_{\text{доп}}$:

$$\Delta = T + T(1 - \alpha) / \alpha = T / \alpha, \qquad \varepsilon = vT / \alpha \le \varepsilon_{\text{доп}}. \tag{2}$$

Ограничение снизу для быстрой группы следует из (1). Совместность обоих ограничений даёт условие, не содержащее периода опроса:

$$n_1 \tau_1 v / (\alpha \varepsilon_{\text{доп}}) \le \rho_{\text{доп}} - \rho_{\text{отр}} - \rho_{\text{ост}}. \tag{3}$$

Условие (3) проверяется до выбора периода. При $v = 8$ °C/с, $\varepsilon_{\text{доп}} = 5$ °C, $\alpha = 0{,}4$ и располагаемой доле 1,7 % левая часть (3) для прямого чтения равна 0,072 % (запас в 23 раза, допустимый период от 11 мс до 0,25 с), а для внешних утилит – 36 %: ни при каком периоде оба требования не выполняются, и нужна смена механизма получения показаний.

Граница 0,25 с продиктована наихудшим случаем – быстрым фронтом вблизи порога перегрева. Поэтому предложен адаптивный период: он сокращается до $T_{\min}$ при приближении показания к порогу предупреждения и возвращается к $T_{\max}$ в спокойном режиме. При доле времени p в зоне повышенных показаний средняя частота опроса равна $(1 - p) / T_{\max} + p / T_{\min}$; при $T_{\min} = 0{,}25$ с, $T_{\max} = 4$ с и $p = 0{,}15$ она составляет 0,81 с$^{-1}$ против 4 с$^{-1}$ при постоянном периоде (таблица 2).

Таблица 2

Сопоставление стратегий опроса

Стратегия	Доля ядра	Наихудшая ошибка	Пробуждений в час
Внешние утилиты, 1 с	13 %	20 °C	3 600
Прямое чтение, 0,25 с	0,37 %	5 °C	14 400
Прямое чтение, 0,25–4 с	0,31 %	5 °C	2 925

Нагрузку отображения снижают отделение частоты обновления интерфейса (2 Гц) от периодов опроса, точечное обновление модели только при фактическом изменении значения и приостановка опроса невидимых разделов. Состав групп и их периоды задаются внешним описанием наряду с профилем устройства [4], что позволяет настраивать бюджет под модель без пересборки. Относительное сокращение автономной работы $\eta = \Delta P / (P_0 + \Delta P)$ при $P_0 = 8$ Вт составляет 12 % для реализации на утилитах ($\Delta P = 1{,}1$ Вт) и 3 % для предложенной ($\Delta P = 0{,}25$ Вт) (около 50 мин для аккумулятора 73 Вт·ч). Соотношения (1)–(3) целесообразно включать в регрессионные испытания [5]. Значения τ и ν подлежат уточнению измерениями на целевом оборудовании.

Заключение. Построена модель бюджета процессорного времени подсистемы мониторинга с разбиением показателей на группы с независимыми периодами опроса. Показано, что запаздывание отображения при экспоненциальном сглаживании равно T / α, и получено условие совместимости бюджета и точности, проверяемое на стадии проектирования. Прямое чтение атрибутов через сохранённые дескрипторы снижает нагрузку с 13 до 0,31 % ядра (в 42 раза) и уменьшает наихудшую ошибку с 20 до 5 °C, а адаптивный период сокращает число пробуждений процессора в 4,9 раза.

Информация о финансовой поддержке: *Научные результаты, изложенные в данной статье, были получены в рамках реализации программы стратегического академического лидерства «Приоритет-2030» (соглашение № 075-15-2026-055 от «06» апреля 2026 г.).*

Список литературы

1. Сайфудинов И. Р. Метод выделения значимых областей в графической информации для систем поддержки принятия решений / И. Р. Сайфудинов, В. В. Мокшин, А. П. Кирпичников [и др.] // Вестник Технологического университета. – 2018. – Т. 21, № 6. – С. 146–152. – EDN XUALUT.
2. Gibadullin, R. F. Speech recognition and machine translation using neural networks / R. F. Gibadullin, A. V. Ilin, M. Y. Perukhin // 2021 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM). – Sochi, 2021. – P. 398–403. – DOI 10.1109/ICIEAM51226.2021.9446474.
3. Моисеев, В. С. К задаче определения вероятностных характеристик информационной безопасности разрабатываемых автоматизированных систем управления / В. С. Моисеев, П. И. Тутубалин. – 2007. – Деп. в ВИНИТИ 11.01.2007, № 26-В2007. – EDN PKCNAT.
4. Raikhlin, V. The Influence of the Form of Digital Etalons on the Effectiveness of Associative Security / V. Raikhlin, R. Gibadullin, A. Boyko // Computers. – 2026. – Vol. 15, No. 3. – P. 167. – DOI 10.3390/computers15030167.
5. Рахманов, А. С. Автоматизация тестирования безопасности веб-приложений / А. С. Рахманов, П. И. Тутубалин // Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований: материалы IV Всерос. нац. науч. конф. – Комсомольск-на-Амуре: КнАГУ, 2021. – Ч. 3. – С. 298–301. – EDN MHNKNA.

УДК 004.032.26

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ОПТИМИЗАТОРОВ ДЛЯ МЕТОДА PINN ПРИМЕНЯЕМОГО К УРАВНЕНИЮ ОСЦИЛЛЯТОРА ВАН ДЕР ПОЛЯ

Бабакина А.А., ORCID 0000-0003-3191-5572,
Беловодский В.Н., канд. техн. наук, ORCID 0000-0001-8345-7492
ФГБОУ ВО «Донецкий национальный технический университет», г. Донецк, РФ
babakinaanastacia@yandex.ru, v.belovodskiy@gmail.com

Введение. Физически информированные нейронные сети (Physics-Informed Neural Networks, PINN) представляют собой современный класс моделей машинного обучения, предназначенных для решения дифференциальных уравнений в частных и обыкновенных производных [1]. Ключевая особенность PINN заключается в интеграции физических законов, описываемых дифференциальными уравнениями, непосредственно в функцию потерь нейронной сети [2]. Это позволяет получать решения, которые не только аппроксимируют данные, но и удовлетворяют заданному уравнению, что особенно ценно в задачах, где данные ограничены или зашумлены [4]. Эффективность PINN существенно зависит от выбора оптимизатора, используемого для минимизации функции потерь [3]. В данной статье проводится сравнительный анализ четырёх оптимизаторов – Adam, RAdam, AdamW и L-BFGS – применительно к задаче решения уравнения осциллятора Ван дер Поля. Особое внимание уделяется различиям в их работе, скорости сходимости и достижимой точности.

Основная часть. В рассмотренных источниках [1-4] чаще всего с методом PINN используется четыре оптимизатора, каждый из которых обладает собственными характеристиками, определяющими их поведение при обучении. Оптимизатор Adam представляет собой адаптивный метод стохастического градиентного спуска, в основе которого лежит вычисление оценок первого и второго моментов градиента [3]. Эти оценки позволяют адаптировать скорость обучения для каждого параметра индивидуально, что обеспечивает простоту реализации и устойчивость к выбору начальной скорости обучения. Однако вблизи минимума функции потерь Adam может замедляться, так как его адаптивные свойства снижают эффективную скорость обучения, что приводит к более медленной сходимости по сравнению с методами, учитывающими кривизну функции.

Оптимизатор RAdam является модификацией Adam, в которую добавлена автоматическая коррекция разогрева (warm-up)[3]. Это означает, что на ранних этапах обучения, когда оценки моментов градиента ещё нестабильны, RAdam динамически изменяет эффективную скорость обучения, предотвращая слишком большие шаги и повышая устойчивость процесса. Основное различие с классическим Adam заключается в том, что

RAdam не требует ручной настройки периода разогрева, а автоматически определяет момент, когда оценки моментов становятся достаточно надёжными для полноценного применения адаптивного шага [3]. Это делает RAdam более стабильным на начальном этапе, но в некоторых задачах может приводить к замедлению сходимости.

Оптимизатор AdamW представляет собой вариант Adam с раздельной регуляризацией весов [3]. В классическом Adam регуляризация обычно включается в градиент, что приводит к её взаимодействию с адаптивными моментами и может снижать эффективность. AdamW применяет регуляризацию независимо от адаптивного шага, что улучшает обобщающую способность модели и предотвращает переобучение. Такое разделение позволяет более корректно контролировать величину штрафа за большие веса и обеспечивает лучшую сходимость в задачах с большим числом параметров.

Оптимизатор L-BFGS относится к классу квазиньютоновских методов [3]. В отличие от адаптивных методов, L-BFGS пытается учесть ещё и кривизну функции потерь – насколько быстро меняется градиент при изменении параметров. Для этого метод приближённо восстанавливает обратную матрицу Гессе, которая описывает эту кривизну. Поскольку хранить полную матрицу Гессе для больших нейронных сетей невозможно, L-BFGS использует её ограниченную аппроксимацию, сохраняя лишь информацию о нескольких последних шагах. Ещё одно важное отличие заключается в том, что L-BFGS вычисляет градиент сразу по всем данным. Благодаря учёту кривизны функции потерь он делает более точные шаги и потому сходится быстрее.

Для сравнения эффективности методов рассмотрим пример осциллятора Ван дер Поля, для которого применим метод PINN.

$$\frac{d^2x}{dt^2} - \mu(1 - x^2)\frac{dx}{dt} + x = 0, \qquad (1)$$

где μ – положительный параметр, характеризующий силу нелинейности и «силу» затухания колебаний, возьмём его равным 1. Начальные условия возьмём x(0) = 2.0 , x'(0) =0.

Архитектура сети состоит из одного нейрона входного слоя, 3 слоёв внутренних по 40 нейронов каждый, и одного выходящего нейрона, функция активации гиперболический тангенс. Ошибка целевой функции не должна превышать 0,001, максимальное количество эпох задавалось 30000, начальная скорость обучения 0,001. Решение методом PINN находится на 1 периоде (2000 т.), а затем строится несколько раз на промежутке от 0 до 30.

В таблице представлены результаты сравнения оптимизаторов по количеству эпох, времени обучения и достигнутой величине ошибки. На рисунке представлен график решения Задачи Коши уравнения (1).

Анализ результатов показывает, что L-BFGS демонстрирует наилучшую точность ($5.62 \cdot 10^{-4}$) и минимальное время обучения (1.21с), что

объясняется его способностью использовать информацию о кривизне функции потерь. Но он требует вычисления градиентов на полном батче, что может быть ограничением при больших объёмах данных. Adam и AdamW показали близкие результаты по точности и количеству эпох, но AdamW потребовал значительно больше времени (5.87с), что связано с дополнительными вычислениями при раздельной регуляризации. RAdam оказался самым медленным (9.30с) и достиг лишь целевой ошибки $1.00 \cdot 10^{-3}$.

Таблица

Сравнение методов

Метод	Количество эпох	Время	Величина ошибки
Adam	846	6.11с	$9.99 \cdot 10^{-4}$
RAdam	1236	9.30с	$1.00 \cdot 10^{-3}$
AdamW	846	5.87с	$9.98 \cdot 10^{-4}$
L-BFGS	7	1.21с	$5.62 \cdot 10^{-4}$

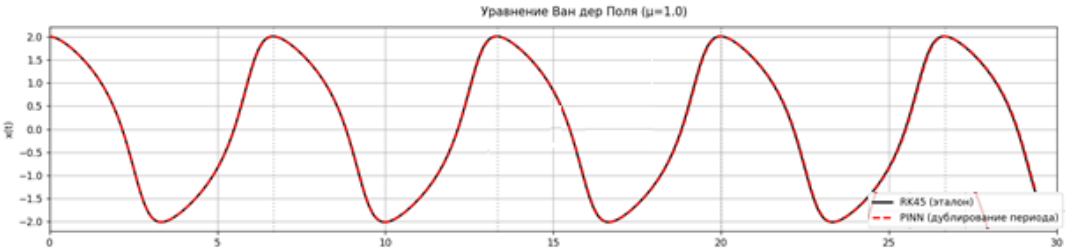


Рис. Решение уравнения Ван дер Поля

Заключение. Проведён сравнительный анализ оптимизаторов для PINN применительно к уравнению осциллятора Ван дер Поля. Установлено, что L-BFGS обеспечивает наилучшую точность и скорость сходимости, но его применение ограничено задачами с небольшим числом параметров и гладкими функциями потерь. Adam и AdamW показали устойчивые результаты. RAdam был наименее эффективен в данной задаче.

Список литературы

1. Khanra, S. Physics-informed neural networks for differential equation solutions: A comprehensive review / S. Khanra, V. K. Kukreja, I. Bala // Neurocomputing. – 2026. – Vol. 680. – 133317. – DOI 10.1016/j.neucom.2026.133317.
2. Farea, A. Understanding Physics-Informed Neural Networks: Techniques, Applications, Trends, and Challenges / A. Farea, O. Yli-Harja, F. Emmert-Streib // AI. – 2024. – Vol. 5, № 3. – P. 1534–1557. – DOI 10.3390/ai5030074.
3. Kopaničáková, A. Introduction to optimization methods for training SciML models : preprint / A. Kopaničáková, E. Riccietti. – [Б. м.], 2026. – URL: Kopaničáková, A. Introduction to optimization methods for training SciML models: preprint / A. Kopaničáková, E. Riccietti. – [Б. м.], 2026. – URL: https://arxiv.org/abs/2601.10222 (дата обращения: 08.10.2026). (дата обращения: 08.10.2026).
4. Becerra-Zuñiga, N. On the Role of Consistency Between Physics and Data in Physics-Informed Neural Networks / N. Becerra-Zuñiga, L. Lacasa, E. Valero, G. Rubio // arXiv. – 2026. – arXiv:2602.10611. – URL: https://arxiv.org/abs/2602.10611 (дата обращения: 08.10.2026).

УДК 004.85

ОСОБЕННОСТИ АЛГОРИТМОВ ОПТИМИЗАЦИИ И ФОРМИРОВАНИЯ ФУНКЦИЙ ПОТЕРЬ ПРИ НЕЙРОСЕТЕВОМ РЕШЕНИИ ДИФФЕРЕНЦИАЛЬНЫХ УРАВНЕНИЙ

Бабич И.В., ORCID 0009-0001-0763-2700
ФГБОУ ВО «Донецкий национальный технический университет», г. Донецк, РФ
babichivanvictorovich@yandex.ru

Введение. При нейросетевом решении дифференциальных уравнений важен не только вид сети, но и способ обучения. В PINN уравнение, граница и начальное состояние входят в общую функцию потерь [1]. Цель работы – сравнить постоянные и обучаемые веса при использовании Adam и L-BFGS на фиксированной задаче теплопроводности.

Формирование функции потерь. Для $L = \lambda r Lr + \lambda b Lb + \lambda_0 L_0$ величины L_j представляют средние квадраты соответствующих невязок. Направление обновления параметров определяется суммой $\lambda j \nabla \theta L_j$. Поэтому малая величина компонента потерь сама по себе не означает слабое влияние её градиента. Несбалансированность градиентов и адаптация весов по их статистике рассмотрены в [2].

В SA-PINN [3] каждому обучающему узлу назначается собственная маска, а не один общий коэффициент для всего уравнения:

$$min_\theta max_s L(\theta, s), L = \sum_{j\in\{r,b,0\}} \frac{1}{N_j} \sum_{i=1}^{N_j} s_{j,i}^2 e_{j,i}(\theta)^2.$$

Параметры θ обновляются на уменьшение L, параметры s – на увеличение; начальные s равны 1. Узлы с сохраняющейся ошибкой получают больший вес. В данной реализации маски изменяются только на этапе Adam, а при переходе к L-BFGS фиксируются. Это сохраняет одну целевую функцию на этапе квазиньютоновского уточнения. Нормировка по N_j явно отличает реализованный вариант от ненормированных сумм в исходной формулировке [3].

Алгоритмы и протокол. Adam использует оценки первого и второго моментов градиента [5]. L-BFGS строит приближение обратного гессиана по ограниченной истории изменений параметров и градиентов [6]. Сочетание этих методов для PINN исследовано в [4]; универсальная гарантия превосходства из этого не следует.

Тест: $u_t = 0{,}1u_{xx}$ на $(0,1) \times (0,1]$, нулевые значения на концах, $u(x,0) = \sin(\pi x)$; эталон $u^* = \exp(-0{,}1\pi^2 t)\sin(\pi x)$. Постановка и базовый гибридный расчёт общие с отдельной работой автора о точности краевых задач; здесь исследуется именно обучение. Сеть 2–32–32–32–1, tanh; 1024 внутренних, 128 граничных, 128 начальных точек. Внутренние эталонные значения не используются при обучении.

Сравниваются Adam (3000 шагов), Adam + L-BFGS и SA-PINN + L-BFGS (2000 шагов Adam и 500 итераций L-BFGS). Шаг Adam для сети и масок – 10^{-3}; поиск шага L-BFGS – strong Wolfe, память 50 пар. Точки фиксированы; для каждого seed 17, 42, 123 начальные параметры сети совпадают между режимами. CPU AMD Ryzen 5 5600, один поток, PyTorch 2.14.1, float64. Контрольная сетка 101 × 101 не участвует в обучении.

Таблица

Сравнение обучения, среднее ± s по трём запускам

Режим	**$E_2 \cdot 10^4$**	**$Rr \cdot 10^3$**	**Время, с**
Adam	14,22 ± 6,50	5,46 ± 2,65	17,93 ± 0,18
Adam + L-BFGS	2,47 ± 0,94	0,76 ± 0,11	15,71 ± 0,03
SA-PINN + L-BFGS	2,38 ± 0,93	0,68 ± 0,13	16,65 ± 0,45

E_2 – относительная L_2-ошибка; Rr – RMS невязки уравнения; s – выборочное стандартное отклонение. Время обучения без диагностики.

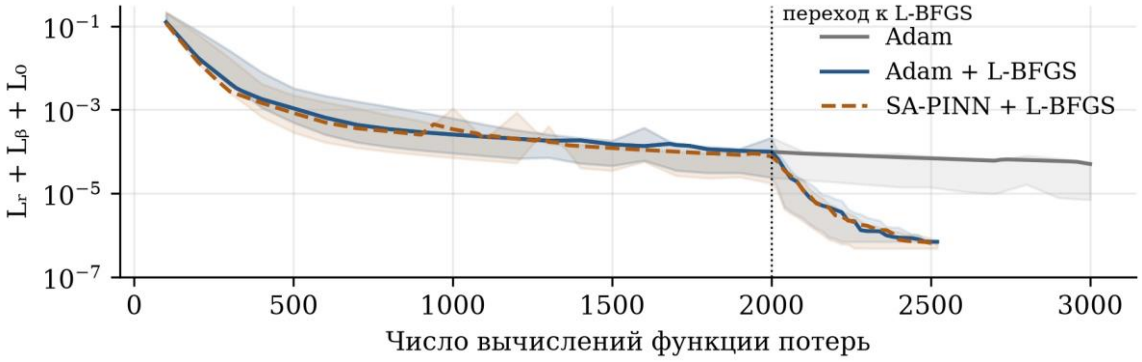


Рис. Невзвешенная сумма потерь: медиана и диапазон трёх запусков

Обсуждение. Переход к L-BFGS снизил среднюю E_2 в 5,75 раза относительно выбранного бюджета Adam. Добавление масок дало ещё 3,9 % снижения средней E_2; различие мало на фоне разброса и не доказывает общего преимущества SA-PINN. Во всех гибридных запусках достигнут лимит 500 итераций, а не подтверждён глобальный минимум.

При seed 42 после Adam значения L_r, L_b, L_0 равны $5{,}18 \cdot 10^{-5}$, $1{,}72 \cdot 10^{-6}$, $2{,}54 \cdot 10^{-6}$, тогда как нормы их градиентов – $2{,}11 \cdot 10^{-3}$, $6{,}35 \cdot 10^{-3}$, $7{,}21 \cdot 10^{-3}$. Следовательно, сравнение одних потерь не выявляет вклады в шаг обучения. Сильного отказа решения на этом гладком тесте не наблюдалось.

Средние числа вычислений обучающей функции: 3000, 2553 и 2571 соответственно. Итерация L-BFGS может включать несколько пробных вычислений при поиске шага; рисунок включает такие точки. Времена относятся к конкретной реализации и не означают сравнение при строго одинаковом вычислительном бюджете.

Адаптивные коэффициенты также сохранялись отдельно от весов сети. Для seed 42 к завершению этапа Adam их диапазоны s^2 составили

1,09–3,47 для уравнения, 1,29–1,55 для границы и 1,05–1,45 для начального профиля. Таким образом, даже одна компонента потерь получает неоднородное по узлам усиление. При этом большее значение маски не является оценкой физической ошибки: оно зависит от всей истории обучения.

При сопоставлении режимов использована невзвешенная сумма $L_r + L_b + L_0$: оптимизируемые взвешенные суммы в SA-PINN и базовой сети напрямую несопоставимы. Начальные состояния сети одинаковы для парных запусков, а контрольная сетка не использовалась для остановки или подбора параметров. Для расширения выводов потребуются другие коэффициенты диффузии, более сложные начальные профили и больше повторений; здесь исследуется один фиксированный тест.

Заключение. Для данного теста основное улучшение связано с квазиньютоновским уточнением, а эффект адаптивных масок невелик. В программном комплексе следует сохранять отдельно компоненты потерь, нормы градиентов, контрольную ошибку и стоимость обучения; выбирать стратегию по этим измерениям, а не только по минимуму взвешенной суммы.

Список литературы

1. Raissi, M. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations / M. Raissi, P. Perdikaris, G. E. Karniadakis // Journal of Computational Physics. – 2019. – Vol. 378. – P. 686–707. – DOI 10.1016/j.jcp.2018.10.045.
2. Wang, S. Understanding and Mitigating Gradient Flow Pathologies in Physics-Informed Neural Networks / S. Wang, Y. Teng, P. Perdikaris // SIAM Journal on Scientific Computing. – 2021. – Vol. 43, № 5. – P. A3055–A3081. – DOI 10.1137/20M1318043.
3. McClenny, L. D. Self-adaptive physics-informed neural networks / L. D. McClenny, U. M. Braga-Neto // Journal of Computational Physics. – 2023. – Vol. 474. – Art. 111722. – DOI 10.1016/j.jcp.2022.111722.
4. Challenges in Training PINNs: A Loss Landscape Perspective / P. Rathore, W. Lei, Z. Frangella [et al.] // Proceedings of the 41st International Conference on Machine Learning. – 2024. – Vol. 235. – P. 42159–42191. – (Proceedings of Machine Learning Research). – URL: https://proceedings.mlr.press/v235/rathore24a.html (дата обращения: 07.10.2026).
5. Kingma, D. P. Adam: A Method for Stochastic Optimization / D. P. Kingma, J. Ba // 3rd International Conference on Learning Representations (ICLR 2015). – 2015. – URL: https://arxiv.org/abs/1412.6980 (дата обращения: 07.10.2026).
6. Liu, D. C. On the limited memory BFGS method for large scale optimization / D. C. Liu, J. Nocedal // Mathematical Programming. – 1989. – Vol. 45. – P. 503–528. – DOI 10.1007/BF01589116.

УДК 004.896

СРАВНЕНИЕ КЛАССИЧЕСКОГО И ОБУЧАЕМЫХ С ПОДКРЕПЛЕНИЕМ АЛГОРИТМОВ ПРЕДОТВРАЩЕНИЯ СТОЛКНОВЕНИЙ ДЛЯ МОБИЛЬНОЙ РОБОТОТЕХНИЧЕСКОЙ ПЛАТФОРМЫ

Бабошин С.А., ORCID 0009-0004-3265-6386,
Андриян О.В., ORCID 0009-0005-2211-2251
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
Sbaboshin1@gmail.com, 1_solnishko@mail.ru

Введение. Автоматическое предотвращение столкновений востребовано в широком спектре автономных и полуавтономных систем – от ADAS в автомобилях до промышленных AGV. При этом приходится решать две задачи одновременно: надёжно обнаруживать угрозу с помощью недорогих датчиков и корректно корректировать движение, не вмешиваясь излишне в управление оператором. В рассматриваемой архитектуре оператор сохраняет полный контроль, а supervisor вносит поправки (масштаб скорости, добавка к повороту, аварийный стоп) только при появлении угрозы.

Открытым остаётся вопрос: оправдано ли добавление обучаемого компонента поверх классического алгоритма? Похожее сравнение (классический метод искусственных потенциальных полей против гибридной и полностью обучаемой RL-конфигураций) было выполнено для независимой задачи управления роем БПЛА при слежении за фронтом пожара, где хорошо настроенный классический алгоритм превзошёл обе обучаемые надстройки. Настоящая работа проверяет, воспроизводится ли эта закономерность на объекте иной физической природы – наземной платформе с дифференциальным приводом и ультразвуковыми/лазерным дальномерами.

Материалы и методы. Платформа и симулятор. Моделируется RC-платформа на дифференциальном приводе с пятью ультразвуковыми (HC-SR04) и одним лазерным (VL53L1X) дальномерами. Симулятор воспроизводит кинематику привода с инерцией моторов, коническое сканирование датчиков с шумом и задержкой опроса, движущиеся и статичные препятствия на арене 6×6 м.

Сравниваемые контроллеры. TTC – supervisor, вычисляющий время до столкновения по каждому датчику и ограничивающий скорость/траекторию при его снижении ниже порога [1]. TTC+PPO – та же логика, поверх которой RL-политика (PPO) добавляет ограниченную по амплитуде поправку; аварийный стоп агент отменить не может. PPO – политика управляет платформой напрямую, без обращения к TTC [2].

Задача и протокол оценки. Робот последовательно посещает 3 контрольные точки; формирующий курс driver не видит препятствий – уклонение целиком возлагается на supervisor. Использованы три сценария (без препятствий, статичные, движущиеся) и два уровня шума датчиков (штатный и усиленный, включающий дрейф калибровки, пакетные пропуски и перекрёстные наводки). Обучение PPO [1] – 300 000 шагов (stable-baselines3, нормализация наблюдений VecNormalize); для контроля случайности инициализации использовано 3–5 независимых обучающих запусков на конфигурацию. Seed'ы разделены на валидационную (подбор функции вознаграждения, 100 эпизодов/сценарий) и тестовую (только итоговое сравнение, 100 эпизодов/сценарий, ранее не использовалась) выборки. Для парных бинарных исходов (столкновение/нет) применён точный биномиальный тест по дискордантным парам при $\alpha = 0.05$.

Функция вознаграждения. Штраф за столкновение −50 обеспечивает стабильное обучение при повышенной частоте столкновений со статичными препятствиями; усиление штрафа до −150 снижает её почти вдвое ценой расхождения обучения (до 67 % запусков) – типичного для RL вырожденного локального оптимума «не двигаться». Для итогового сравнения использованы сошедшиеся запуски при усиленном штрафе (отбор по скорости в сценарии без препятствий).

Результаты. На тестовой выборке TTC+PPO не показал статистически значимых отличий от TTC ни в одной из четырёх проверенных конфигураций вознаграждения ($|\Delta| \leq 2.4$ п.п. по всем метрикам) и исключён из таблицы результатов. Показатели для TTC и PPO (среднее по 3 обучающим запускам) приведены в таблице.

Таблица

Доля столкновений и средняя скорость на тестовой выборке
(100 сценариев × 3 обучающих запуска)

Сценарий	Шум	Столкн. TTC, %	Столкн. PPO, %	Скор. TTC, м/с	Скор. PPO, м/с
статичные	штатный	2.0	9.3	0.52	0.64
движущиеся	штатный	34.0	21.7	0.57	0.76
статичные	усиленный	12.0	15.7	0.50	0.65
движущиеся	усиленный	46.0	32.3	0.48	0.70

Парная проверка значимости показала: на статичных препятствиях при штатных датчиках PPO статистически значимо чаще сталкивается, чем TTC ($p < 0.05$ в 2 из 3 запусков, направление эффекта единообразно во всех трёх); при усиленном шуме различие незначимо ($p > 0.13$ во всех

запусках). На движущихся препятствиях PPO значимо безопаснее TTC при обоих уровнях шума ($p < 0.05$ в 2 из 3 запусков, направление эффекта единообразно во всех трёх запусках и обоих условиях шума). Скорость PPO во всех условиях на 20–45 % выше.

Анализ минимальной дистанции, зафиксированной датчиками непосредственно перед столкновением, вскрывает различную природу отказов: у TTC столкновения происходят при стабильно критической дистанции (≈0.13 м – «не успел среагировать»), тогда как у PPO часть столкновений происходит при дистанции до 0.8–1.3 м, то есть препятствие было обнаружено заблаговременно, но политика не уклонилась. Это указывает на поведенческое, а не сенсорное ограничение.

Обсуждение и заключение. Результаты в целом воспроизводят закономерность, полученную для роя БПЛА: остаточная RL-надстройка над хорошо настроенным классическим алгоритмом, не даёт измеримой пользы [3]. Полностью обучаемый контроллер, однако, демонстрирует не худший, а качественно иной профиль риска – статистически значимое на независимой тестовой выборке преимущество против динамических угроз ценой повышенного риска при статичных препятствиях, устранимого дальнейшей работой с функцией вознаграждения, а не заменой датчиков.

Практический вывод для переноса на реальную платформу: классический TTC-supervisor остаётся предпочтительным для немедленного внедрения как предсказуемый и не требующий обучения вариант, тогда как обучаемый контроллер – перспективное направление, требующее дальнейшей стабилизации обучения и валидации на реальном оборудовании [4]. Ограничения работы: все результаты получены в симуляции; число независимых обучающих запусков (3–5) ограничивает статистическую мощность; модель шума датчиков не откалибрована по измерениям реального оборудования.

Список литературы

1. Schulman J. Proximal Policy Optimization Algorithms / J. Schulman, F. Wolski, P. Dhariwal [et al.] // arXiv preprint arXiv:1707.06347. – 2017.
2. Sutton R. S. Reinforcement Learning: An Introduction / R. S. Sutton, A. G. Barto. – 2nd ed. – Cambridge, MA: MIT Press, 2018. – 552 p.
3. Акимов А. А. Многоуровневая стратегия безопасной навигации и распределения роя БПЛА для мониторинга лесных пожаров / А. А. Акимов, Ю. А. Гнатенко, Р. Г. Болбаков // Робототехника, автоматизация и системы управления. – 2026. – URL: https://www.ia.spcras.ru/index.php/sp/article/view/17402 (дата обращения: 06.10.2026). – Текст: электронный.
4. Diaz-Vilor C. A Reinforcement Learning Approach for Wildfire Tracking With UAV Swarms / C. Diaz-Vilor, A. Lozano, H. Jafarkhani // IEEE Transactions on Wireless Communications. – 2025. – Vol. 24, № 4. – P. 3120–3134. – DOI 10.1109/TWC.2024.3524324.

УДК 004.932.72

СИСТЕМА РЕКОМЕНДАЦИЙ ДЛЯ ПЛАТФОРМ ОНЛАЙН-ВИДЕОИГР

Бондаренко В.В., ORCID 0009-0001-1467-9945,
Позывной Н.К., ORCID 0009-0005-3177-5946
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
vk.bondarenko@donnu.ru, nikita.retina@gmail.com

Введение. Индустрия видеоигр стала одной из наиболее значимых в мире: в 2022 году более 2,5 миллиардов человек уделяли часть своего времени видеоиграм, а в 2023 году выручка отрасли выросла на 10,7 %, превысив 116 миллиардов долларов. Широкий выбор игровых платформ, жанров и категорий игр делает задачу выбора новой игры для пользователя все более сложной [1].

Так, к серверам платформы цифровой дистрибуции STEAM ежечасно подключаются более 10 миллионов человек, при этом, по данным платформы за 2014 год, около 37 % купленных игр так и не были запущены их владельцами. Это обуславливает необходимость в рекомендательных системах, которые формируют персонализированные рекомендации и помогают пользователю находить новые и малоизвестные игры.

Цель работы – исследование современных рекомендательных систем в контексте видеоигр с оценкой не только точности ранжирования рекомендаций, но и их новизны и разнообразия, а также анализ влияния текстовых отзывов пользователей на качество рекомендаций.

Набор данных. Исследование проводилось на трех наборах данных платформы STEAM, собранных с октября 2015 по январь 2023 года: история покупок пользователей из России с указанием времени игры, текстовые отзывы пользователей и сведения о жанрах и доступности игр. Исходный набор содержал около 5,15 млн записей (70 912 пользователей и 10 978 игр) при плотности 0,66 %. Для ее повышения были оставлены игры, приобретенные не менее 200 раз, и пользователи, совершившие не менее 100 покупок. Итоговый набор включает 2 149 858 записей, 8 183 пользователя и 2 872 игры при плотности 9,14 %. Поскольку явного рейтинга нет, использовалась неявная обратная связь: интерес к игре фиксировался при игровом времени не менее 5 часов.

Рассматриваемые модели. Для сравнения были выбраны модели, основанные на различных подходах к рекомендациям и способные обрабатывать разные типы входных данных:

Чередующиеся наименьшие квадраты (ALS) – модель матричной факторизации для неявной обратной связи, учитывающая как предпочтение пользователя, так и уверенность в нем. Используется в качестве базовой модели [3].

Факторизационные машины (FM) – модели, обрабатывающие непрерывные и дискретные признаки и учитывающие парные взаимодействия между ними (порядок n = 2).

DeepNN и DeepFM – модели глубокого обучения. DeepNN представляет собой нейронную сеть прямого распространения со слоем встраивания, извлекающую взаимодействия признаков высокого порядка. В DeepFM компоненты FM и DNN работают параллельно, а их выходы объединяются сигмоидальной функцией [2].

Результаты. Для ALS были выбраны 500 скрытых факторов, коэффициент регуляризации $\lambda = 0{,}01$ и 300 итераций обучения. Для моделей глубокого обучения анализ чувствительности показал, что уменьшение размера пакета с 1024 до 512 и числа нейронов в слое с 32 до 8 улучшает все показатели. По результатам тестирования базовая модель ALS обучается быстрее остальных, но показывает наименьшую точность (MAP = 0,107). Наилучшие результаты получены у модели DeepNN с учетом анализа отзывов пользователей: MAP = 0,897, новизна – 0,197, разнообразие – 0,54 (для сравнения, у DeepFM без учета отзывов – 0,891; 0,167 и 0,43 соответственно).

Заключение. Результаты показывают, что взаимодействия признаков высокого порядка, извлекаемые DeepNN, несут больше информации, чем взаимодействия низкого порядка в FM, и в составе DeepFM последние могут ухудшать итоговый результат. Учет текстовых отзывов пользователей повышает новизну и разнообразие рекомендаций для всех рассмотренных моделей, что особенно важно для игровой индустрии, где эти показатели играют ключевую роль.

В дальнейших исследованиях планируется заменить фиксированный порог игрового времени более точными способами оценки интереса пользователя к игре.

Список литературы

1. Bertens, P. A Machine-Learning Item Recommendation System for Video Games / P. Bertens, A. Guitart, P. P. Chen, Á. Periáñez // 2018 IEEE Conference on Computational Intelligence and Games (CIG). – 2018. – P. 1–4.
2. Guo, H. DeepFM: a factorization-machine based neural network for CTR prediction / H. Guo, R. Tang, Y. Ye [et al.] // Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI). – 2017. – P. 1725–1731.
3. Hu, Y. Collaborative filtering for implicit feedback datasets / Y. Hu, Y. Koren, C. Volinsky // 2008 Eighth IEEE International Conference on Data Mining (ICDM). – 2008. – P. 263–272.

УДК 004.42:378.14

АВТОМАТИЗАЦИЯ ЗАПИСИ ПОСТУПАЮЩИХ И ПРОВЕДЕНИЯ ВСТУПИТЕЛЬНЫХ ИСПЫТАНИЙ В СИСТЕМЕ ДИСТАНЦИОННОГО ОБУЧЕНИЯ MOODLE

Бондаренко В.И., канд. техн. наук, доц., ORCID 0000-0002-5404-5787
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
bondarenko@donnu.ru

Введение. В приёмную кампанию 2026 г. Донецкий государственный университет провёл вступительные испытания (ВИ) почти полностью дистанционно: из 21 677 записей вида «поступающий – экзамен» на тестирование в Moodle пришлось 96,5 %. Сведения о поступающих вуз получает из суперсервиса «Поступление в вуз онлайн» в виде Excel-выгрузок, которые меняются несколько раз в сутки. Moodle об этих людях ничего не знает: учётные записи, курсы-предметы и группы по датам создаются в нём отдельно, а по окончании испытания баллы надо передать приёмной комиссии и опубликовать в сроки, которые устанавливает Порядок приёма [1].

Ранее автор организовывал тестовый контроль в Moodle [2], разрабатывал сервис дистанционной подачи документов [3], контроль практики в 1С:Университет ПРОФ [4] и образовательный веб-портал [5]. Этот опыт показал, что при тысячах участников узким местом становятся не сами тесты, а согласование данных между системами. Цель работы – программный комплекс, который берёт на себя весь путь от выгрузки суперсервиса до опубликованного балла.

Основная часть. Комплекс написан на Python и работает под Windows, Linux и macOS. Каждый запуск обрабатывает свежую выгрузку целиком и сравнивает её с фактическим состоянием Moodle, а не с прошлым запуском. Поэтому повторный прогон безопасен: уже записанные пропускаются, новые создаются, расхождения попадают в отчёты. Чтобы не делать тысячи обращений к базе Moodle через защищённый канал, состояние всех записей на курсы ВИ читается одним SQL-запросом; изменения вносятся через Moodle Web Services [6]. Учётная запись создаётся по правилам, согласованным с приёмной комиссией; каждому предмету отвечает свой курс, каждой дате экзамена – группа.

Строка выгрузки проходит фиксированную цепочку шагов. Сначала записи о вступительных испытаниях связываются с заявлениями по идентификатору поступающего. Затем отбрасываются люди, у которых все экзамены уже в прошлом, и предметы, которые сдаются не в Moodle. Дата сверяется с расписанием, после чего идут поиск дубликатов, конфликтов контактов и проверка, записан ли человек. Правила построения полей вынесены в отдельный модуль из функций без побочных эффектов: их

легко проверять по отдельности, а поправка в одном правиле не затрагивает чтение файлов и обращения к Moodle. Все действия, меняющие Moodle, по умолчанию выполняются в режиме предварительного просмотра; изменения вносятся только по явному указанию оператора.

Больше всего труда потребовали не создание записей, а изменения. При переносе экзамена членство меняется в два действия: новая группа добавляется, прежняя снимается. Суперсервис иногда возвращает прежнюю дату, и без контроля человек «качался» бы между группами, поэтому все применённые переносы пишутся в журнал, а повторную или встречную операцию комплекс оставляет до решения оператора. Противоречия разрешает архив из 127 прошлых выгрузок: по нему устанавливается, где дата новее. Если по предмету уже выставлена оценка, перенос запрещён. У дополнительного набора календарь и курсы совпадали с основным, поэтому набор указывается в названии группы, а пересдающего дописывают в новую группу, не отрывая старую оценку от даты сдачи. Перед стартом допнабора результаты основного набора сохраняются отдельным снимком: курс по предмету общий, и пересдача ложится в тот же журнал оценок.

Отдельные проверки ловят ошибки исходных данных: сверка дат с официальным расписанием ВИ, совпадение email или СНИЛС у разных поступающих, повторные заявления одного человека, уже ставшие двумя учётными записями. Недоступность базы данных или файла не останавливает работу: комплекс предупреждает и продолжает с пометкой «не проверено». Показательным вышел дефект чтения: если в числовом столбце Excel есть пустые ячейки, pandas приводит весь столбец к вещественному типу, и у идентификатора появлялся хвостовой ноль от дробной части, так что у части учётных записей начальный пароль оказался неверным. Такие аккаунты нашли сверкой хэшей и известили владельцев. После этого правило проекта – тестировать чтение на настоящих файлах; сейчас в комплексе 644 автотеста.

Каждое изменение сопровождается письмом поступающему. Логин и пароль отправляются только при создании учётной записи; при переносе человек получает уведомление с новой датой. Тех, кто не явился на экзамен, переводят на резервный день отдельным шагом и с отдельным текстом письма. Журнал отправленного не даёт известить человека дважды, а ответы почтовых серверов о недоставке разбираются в почтовом ящике по протоколу IMAP и сопоставляются с поступающими, чтобы оператор мог исправить адрес.

Для предметных комиссий сделано веб-приложение: выбор предмета и даты, перевод первичного балла в итоговый по утверждённой шкале, выгрузка ведомостей и данных для 1С. Ведомости очных испытаний, заполненные комиссией, загружаются обратно и служат вторым источником баллов. Результаты публикуются на сайте donnu.ru по таймеру после истечения регламентного срока.

Результаты. За период 30.06–21.08.2026 через комплекс прошли 5 941 поступающий и 263 экзаменационные сессии в 19 курсах за 30 дат. Применено 1 442 переноса и 29 отмен, отправлено 5 544 письма. К 17 августа на сайте опубликовано 14 477 результатов.

Заключение. Опыт кампании показывает, что устойчивость дистанционных ВИ зависит прежде всего от согласованности данных, а не от тестирующей платформы. Сравнение с реальным состоянием Moodle, журнал операций и защита уже выставленных оценок позволили одному исполнителю обслужить почти шесть тысяч поступающих. Для комплекса подготовлены документы на государственную регистрацию программы для ЭВМ; он может быть применён в других вузах, использующих Moodle.

Список литературы

1. Об утверждении Порядка приема на обучение по образовательным программам высшего образования – программам бакалавриата, программам специалитета, программам магистратуры: приказ Минобрнауки России от 27.11.2024 № 821: зарегистрирован в Минюсте России 29.11.2024 № 80379. – URL: https://legalacts.ru/doc/prikaz-minobrnauki-rossii-ot-27112024-n-821-ob-utverzhdenii/ (дата обращения: 04.10.2026).
2. Бондаренко, В. И. Организация тестового контроля знаний студентов в системе дистанционного обучения Moodle / В. И. Бондаренко, В. В. Бодряга, В. В. Бондаренко // Донецкие чтения 2019: образование, наука, инновации, культура и вызовы современности: материалы IV Междунар. науч. конф. – Т. 1, ч. 1: Физико-математические и технические науки. – Донецк: Изд-во ДонНУ, 2019. – С. 204–207. – EDN LAPAYU.
3. Пугач, А. А. Микросервисы в системе дистанционной подачи документов в вуз / А. А. Пугач, В. И. Бондаренко, В. В. Бондаренко // Донецкие чтения 2020: образование, наука, инновации, культура и вызовы современности: материалы V Междунар. науч. конф. (Донецк, 17–18 ноября 2020 г.). – Донецк: Изд-во ДонНУ, 2020. – С. 274–277. – EDN EQKJFV.
4. Бондаренко, В. И. Контроль проведения практики студентов с помощью АИС 1С: Университет ПРОФ / В. И. Бондаренко, С. М. Романчук // Актуализация практической подготовки студентов в условиях внедрения федеральных государственных образовательных стандартов 3++. – 2020. – С. 222–226. – EDN TRTAYT.
5. Бондаренко, В. И. Применение современных веб-технологий для автоматизации учебной деятельности на примере образовательного портала / В. И. Бондаренко, А.-А. М. Мартыненко, С. В. Придворов // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2025. – № 4. – С. 93–101. – DOI 10.5281/zenodo.18229815. – EDN EEMGVD.
6. Web services. – Текст: электронный // MoodleDocs: [сайт]. – URL: https://docs.moodle.org/en/Web_services (дата обращения: 04.10.2026).

УДК 004.912

АВТОМАТИЧЕСКОЕ РЕФЕРИРОВАНИЕ И КЛАССИФИКАЦИЯ РЕЛЕВАНТНОСТИ НАУЧНЫХ ТЕКСТОВ

Бондаренко В.И., канд. техн. наук, доц., ORCID 0000-0002-5404-5787,
Калоша А.Г.
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
bondarenko@donnu.ru, aleksey-kalosha@mail.ru

Введение. Рост числа научных публикаций затрудняет поиск и анализ информации. Реферирование кратко представляет содержание статьи, а классификация помогает отбирать материалы для профессиональных групп. При обработке научного текста необходимо сохранять терминологию, численные данные и ограничения исследования. Практическое применение также требует приемлемых затрат памяти и времени.

Цель исследования – разработка и исследование методов автоматического реферирования и классификации релевантности научных текстов с использованием современных моделей обработки естественного языка. Задачи включают подготовку корпуса данных, сравнение моделей разных размеров, дообучение и оценку качества и ресурсных требований.

Основная часть. Экстрактивное реферирование отбирает предложения оригинала, абстрактивное генерирует краткий текст [1]. Аннотирование текстов разных жанров рассмотрено в [2]. Основной акцент планируется сделать на компактных encoder–decoder-моделях, например ruT5-base, mT5-small и mBART [3–5]. Малые конфигурации Qwen3.5 и Gemma 4 также могут участвовать в сравнении. Предполагается выбрать 3–5 кандидатов с учётом языка, длины контекста и оборудования. Окончательный выбор не закрепляется за конкретным семейством.

Корпус, используемый для дообучения и тестирования, должен содержать пары «научный текст – эталонный реферат» и тематические метки. Авторские аннотации проверяются на полноту и исключаются из входа, если служат эталоном. Обучающая, валидационная и тестовая выборки не должны пересекаться по статьям, дубликатам и версиям. Для длинных документов сравниваются обработка целиком и поэтапное реферирование разделов.

Сравниваются готовые реферирующие контрольные точки. Базовые модели без такой адаптации предварительно обучаются задаче. Устанавливаются общий лимит длины реферата и сопоставимые условия генерации. По валидации выбирается кандидат с достаточным качеством и меньшими ресурсными затратами. Затем проверяется адаптация к научным текстам: полное дообучение компактной модели либо LoRA/QLoRA при подходящей реализации [6]. Изменение качества оценивается на независимом тесте.

Оценка включает ROUGE, BERTScore и экспертную проверку полноты, связности и фактической согласованности. Отдельно фиксируются ошибки в числах, терминах и выводах. Текстовое сходство само по себе не гарантирует достоверность реферата.

Рабочее определение релевантности – соответствие предметной области и профессиональной группе, а не персональная полезность статьи. Для классификации сравниваются TF-IDF с линейным классификатором и компактная семантическая модель. Междисциплинарные публикации могут получать несколько меток. Главными метриками для оценки результатов являются точность, полнота и macro-F1. Классификация научных текстов глубокими моделями исследована в [7].

При запуске на целевом ПК, включая CPU, измеряются время обработки, пиковая память и размер модели. Требования к дообучению оцениваются отдельно.

Заключение. Автоматическое реферирование позволяет сократить объем научного текста при сохранении основных положений, а классификация – определить, каким предметным областям и профессиональным группам соответствует текст. Объединение реферирования и классификации позволяет получить систему предварительного анализа научных публикаций, способную сократить время их изучения и упростить отбор материалов по заданной тематике.

Список литературы

1. Лезгян А. С. Автоматическое реферирование текстов: классификация, архитектуры, современные подходы и проблемы / А. С. Лезгян // Математическое моделирование, компьютерный и натурный эксперимент в естественных науках. – 2023. – № 1. – С. 19–27. DOI: 10.24412/2541-9269-2023-1-19-27.
2. Ермоленко Т. В. Разработка алгоритмов и языковых моделей для мультиязычной системы автоматического аннотирования текстов разных жанров / Т. В. Ермоленко, В. И. Бондаренко, Я. С. Пикалёв // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2023. – № 2. – С. 22–43. EDN: KRDDOO.
3. Zmitrovich D. A Family of Pretrained Transformer Language Models for Russian / Zmitrovich D. [et al.]// LREC-COLING. – 2024. – P. 507–524. URL: aclanthology.org/2024.lrec-main.45.
4. Xue L. mT5: A Massively Multilingual Pre-trained Text-to-Text Transformer / Xue L. [et al.] // NAACL-HLT. – 2021. – P. 483–498. DOI: 10.18653/v1/2021.naacl-main.41.
5. Liu Y. Multilingual Denoising Pre-training for Neural Machine Translation / Liu Y. [et al.] // TACL. – 2020. – Vol. 8. – P. 726–742. DOI: 10.1162/tacl_a_00343.
6. Dettmers T. QLoRA: Efficient Finetuning of Quantized LLMs / Dettmers T. [et al.]. – 2023. arXiv:2305.14314.
7. Бондаренко В. И. Классификация научных текстов с помощью методов глубокого машинного обучения / В. И. Бондаренко // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2021. – № 3. – С. 69–77. EDN: FJPQFE.

УДК 004.451:004.415.2

СЛОЙ АППАРАТНОЙ АБСТРАКЦИИ И ДЕКЛАРАТИВНЫЕ ПРОФИЛИ УСТРОЙСТВ В КРОССПЛАТФОРМЕННОМ ДИАГНОСТИЧЕСКОМ ПРОГРАММНОМ ОБЕСПЕЧЕНИИ

Валитов Р.Р., Юдина А.В.,
Гибадуллин Р.Ф., канд. техн. наук, доц.
ФГБОУ ВО «Казанский национальный исследовательский технический университет – Казанский авиационный институт им. А. Н. Туполева», г. Казань, РФ
valrus110@gmail.com, annyudina04@yandex.ru, RuslanGibadullin@vk.com

Введение. Переход организаций на отечественные операционные системы (Astra Linux, РЕД ОС, «Альт») изменил требования к средствам обслуживания вычислительной техники. В Linux сведения об оборудовании рассредоточены по консольным утилитам (lm-sensors, smartctl, dmidecode), требующим прав администратора и навыка интерпретации вывода. Поэтому востребовано единое настольное приложение, объединяющее диагностику, электронный паспорт изделия и сервисные функции для всего модельного ряда изготовителя. Поскольку оно обращается к телеметрии, обновлению микропрограмм и удалённому доступу, свойства защищённости должны закладываться на уровне архитектуры [1]. Основная трудность связана с размерностью пространства «операционная система – модель оборудования»: прямое отражение этих различий в коде порождает ветвления, число которых растёт как произведение числа платформ на число моделей.

Цель работы – обосновать архитектуру кроссплатформенного диагностического приложения, в которой платформенные различия локализованы в слое аппаратной абстракции (Hardware Abstraction Layer, HAL), а модельные вынесены в декларативные профили устройств, и оценить выигрыш такого решения с помощью аналитической модели трудоёмкости сопровождения.

Основная часть. Приложение имеет слоистую структуру: интерфейс на Qt Quick / QML, бизнес-логика (агрегация показателей, цветовая индикация, разрешение профилей) и HAL; подобная декомпозиция применяется и в системах поддержки принятия решений [2]. Тип ОС не упоминается выше HAL: интерфейс поставщика данных сформулирован в терминах предметной области (спецификация, датчики, накопители, аккумулятор, порты), а реализация для Linux или Windows выбирается фабрикой на этапе сборки.

Источниками данных в Linux служат sysfs и procfs, hwmon и libsensors, средства SMART, UPower, udev и таблицы DMI/SMBIOS, в Windows – инструментарий WMI и Win32 API. Различия не сводятся к именам источников: hwmon возвращает температуру в тысячных долях

градуса Цельсия, а класс MSAcpi_ThermalZoneTemperature – в десятых долях кельвина ($t = v / 10 - 273{,}15$) и отражает тепловую зону ACPI, а не датчик в кристалле процессора. Нормализацию единиц и выбор источника выполняет адаптер. Адаптеры – единственное место платформенных ошибок, поэтому они тестируются отдельно на фактическом выводе системных интерфейсов, а бизнес-логика – на подставном поставщике [3]. Привилегированные операции (опрос SMART, обновление микропрограмм, удалённый сеанс) вынесены в отдельную службу с закрытым перечнем команд, что ограничивает последствия компрометации интерфейсной части [4].

Различия между моделями носят не алгоритмический, а параметрический характер: состав спецификации, набор датчиков, пороги индикации, перечень разделов интерфейса. Поэтому они описываются данными – профилем модели в формате JSON с наследованием общей части от базового профиля форм-фактора (моноблок, настольный ПК, ноутбук). Профиль проверяется по формальной схеме при сборке и загрузке, а признак необязательности учитывает компоненты, зависящие от комплектации. Близкий принцип – определение поведения внешним описанием – применяется в ассоциативной защите данных [5] и в реализациях криптографических преобразований [6].

Обозначим: N – число ранее поддержанных моделей, M – число модельно-зависимых разделов, c и d – трудоёмкость реализации элемента «модель – раздел» в коде и в профиле, r – трудоёмкость проверки одного сочетания, g – трудоёмкость обобщённого обработчика раздела. В императивной схеме подключение модели требует повторной проверки всех прежних сочетаний, в декларативной – только новой модели:

$$T_{\text{и}}(N) = Mc + rMN, \qquad T_{\text{д}} = M(d + r). \tag{1}$$

Суммарные затраты на поддержку линейки из N моделей:

$$W_{\text{и}}(N) = M[Nc + rN(N - 1) / 2], \qquad W_{\text{д}}(N) = Mg + MN(d + r). \tag{2}$$

Приравнивая выражения (2), получаем уравнение точки окупаемости

$$rN^2 + (2c - 2d - 3r)N - 2g = 0. \tag{3}$$

Для разрабатываемого приложения $M = 6$ (разделы «Домашняя страница», «Система», «Мониторинг», «Устройства и датчики», «Клавиатура», «Обновления»); по опыту разработки приняты $c = 8$ ч, $d = 1{,}5$ ч, $r = 0{,}5$ ч, $g = 24$ ч. Результаты расчёта приведены в таблице.

Таблица

Трудоёмкость поддержки модельного ряда, чел.-ч

Показатель	**Императивная схема**	**Декларативная схема**
Подключение первой модели ($N = 0$)	48	12
Подключение одиннадцатой модели ($N = 10$)	78	12
Единовременные затраты $C_0 = Mg$	–	144
Линейка из 12 моделей, $W(12)$	774	288
Линейка из 24 моделей, $W(24)$	1980	432

Корень уравнения (3) $N^{*} \approx 3{,}6$, т. е. вложения в обобщённые обработчики окупаются на четвёртой модели. Выигрыш определяется прежде всего величиной r: именно регрессионная проверка прежних моделей делает рост суммарных затрат квадратичным. При полностью автоматизированной проверке ($r \to 0$) обе схемы линейны и отношение затрат стремится к $c / d \approx 5{,}3$. Оценки аналитические и подлежат уточнению по фактическим данным.

Заключение. Предложена архитектура кроссплатформенного диагностического приложения, в которой алгоритмические различия платформ локализованы адаптерами слоя аппаратной абстракции, а параметрические различия моделей вынесены в декларативные профили. Показано, что декларативная схема заменяет квадратичный рост затрат на поддержку модельного ряда линейным: для линейки из 12 моделей затраты сокращаются с 774 до 288 чел.-ч (в 2,7 раза), а вложения окупаются на четвёртой модели.

Информация о финансовой поддержке: *Научные результаты, изложенные в данной статье, были получены в рамках реализации программы стратегического академического лидерства «Приоритет-2030» (соглашение № 075-15-2026-055 от «06» апреля 2026 г.).*

Список литературы

1. Тутубалин, П. И. Основные задачи прикладной теории информационной безопасности АСУ / П. И. Тутубалин // Научно-технический вестник Санкт-Петербургского государственного университета информационных технологий, механики и оптики. – 2007. – № 39. – С. 63–72. – EDN JSPVFB.
2. Сайфудинов И. Р. Метод выделения значимых областей в графической информации для систем поддержки принятия решений / И. Р. Сайфудинов, В. В. Мокшин, А. П. Кирпичников [и др.] // Вестник Технологического университета. – 2018. – Т. 21, № 6. – С. 146–152. – EDN XUALUT.
3. Рахманов, А. С. Автоматизация тестирования безопасности веб-приложений / А. С. Рахманов, П. И. Тутубалин // Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований: материалы IV Всерос. нац. науч. конф. – Комсомольск-на-Амуре: КнАГУ, 2021. – Ч. 3. – С. 298–301. – EDN MHNKNA.
4. Моисеев, В. С. К задаче определения вероятностных характеристик информационной безопасности разрабатываемых автоматизированных систем управления / В. С. Моисеев, П. И. Тутубалин. – 2007. – Деп. в ВИНИТИ 11.01.2007, № 26-В2007. – EDN PKCNAT.
5. Raikhlin, V. The Influence of the Form of Digital Etalons on the Effectiveness of Associative Security / V. Raikhlin, R. Gibadullin, A. Boyko // Computers. – 2026. – Vol. 15, No. 3. – P. 167. – DOI 10.3390/computers15030167.
6. Гибадуллин, Р. Ф. Реализация криптографического алгоритма AES на основе различных технологий распараллеливания / Р. Ф. Гибадуллин, Р. Р. Хабибуллин // Современные стратегии и цифровые трансформации устойчивого развития общества, образования и науки: сб. материалов IV Междунар. науч.-практ. конф. – Москва: Алеф, 2022. – С. 178–184. – DOI 10.34755/IROK.2022.21.21.007.

УДК 631.5(571.17)

ИСПОЛЬЗОВАНИЕ ЭЛЕМЕНТОВ ТОЧНОГО ЗЕМЛЕДЕЛИЯ НА ВЕДУЩИХ СЕЛЬСКОХОЗЯЙСТВЕННЫХ ПРЕДПРИЯТИЯХ КЕМЕРОВСКОЙ ОБЛАСТИ-КУЗБАССА

Васильченко А.М., канд. техн. наук, доц., ***Захаров К.С., Миронова А.В.***
ГПОУ «Кемеровский аграрный техникум» им. Г. П. Левина, п. Металлплощадка,
Кемеровская область – Кузбасс, РФ
info@kat-kem.ru

Введение. В настоящее время оснащение тракторов и комбайнов бортовыми компьютерами со специальным программным обеспечением и интерфейсом позволяет выполнять технологические операции в соответствии с агротехнологическими требованиями возделывания культур на участках любой конфигурации. Предпосылками использования элементов точного земледелия стали современные достижения информационных технологий и результаты ранее проведенных исследований, которые установили оптимальные параметры почвенного плодородия для возделывания культурных растений в конкретных почвенно-климатических условиях.

Цель исследования – мониторинг внедрения и применения системы точного земледелия на ведущих сельскохозяйственных предприятиях Кемеровской области-Кузбасса.

Основная часть. Геоинформационные системы (ГИС) позволяют собрать большой спектр данных о космических и земных факторах продуцирования агроэкосистем, сделать анализ значимости их в формировании продуктивности растений и разработать технологию возделывания культур для хозяйства с учетом состояния почвенного плодородия и требований растений [1].

Новые высокопродуктивные сорта, более широкий спектр среды защиты растений, удобрения, техника нового поколения позволяют осуществлять высокотехнологичные процессы возделывания сельскохозяйственных культур. В тоже время отношение к основному средству производства – почве – остаётся на прежнем уровне. Точное земледелие в адаптивно-ландшафтных системах земледелия является механизмом исполнения агрономических законов: единство организма и среды; совокупного действия факторов жизни растений; возврата элементов питания в почву; минимума оптимума максимума факторов жизни растений и др. Системный подход настраивает последовательность выполнения технологических операций, начиная с дистанционного зондирования Земли и заканчивая конкретным агроприемом с учетом гетерогенности полей фитосанитарного состояния посевов [1].

В Кемеровской области многие руководители хозяйств начали использовать элементы точного земледелия. В Ленинск-Кузнецком

муниципальном районе КФХ Печеркин А. Г. используется штатная навигация на тракторах John Deere 8, 9 серии, опрыскивателе John Deere 4730, а также на комбайнах John Deere 9660. Оборудование и решения для точного земледелия AMS. В данном хозяйстве все функции навигации на технике John Deere в полном объеме не используются, т.к. имеют высокую стоимость за оказание услуг. Последнее приобретение в хозяйстве – Комбайн ACROS 585 плюс. Управлять производственными процессами Комбайн ACROS 585 плюс помогает бортовая информационная система Adviser II, укомплектованная ЖК-монитором. Компьютер обеспечивает ситуационное кадрирование, выполняет голосовое и визуальное оповещение об изменениях. Приложение программы устанавливается на девайс, для контроля работы агрегата в режиме реального времени.

Другая техника предприятия (КАМАЗ, МТЗ) оборудована системой ГЛОНАСС навигация – контроль расхода топлива и местонахождения агрегатов. Используется онлайн-сервис для управления сельхозпредприятием Exact Farming и Космос Агро. По анализу почв предприятие работает с ООО «Центр передового земледелия» КАО «Азот».

Одно из ведущих с/х предприятий Гурьевского района ИП Мовсесян А.А. занимается производством зерновых культур. Одно из первых хозяйств в области, в котором начали применять универсальное жидкое минеральное удобрение карбамидно-аммиачную смесь (КАС). КАС – единственное азотное удобрение, которое содержит три формы азота: нитратную, аммонийную, амидную. Используется штатная навигация на тракторах John Deere 6 – 9 серии, опрыскивателе John Deere 4730, John Deere 9660. Используют онлайн-сервис для управления Космос Агро и Метеостанция. По анализу почв работают с ООО «Центр передового земледелия» КАО «Азот».

Крестьянско-фермерское хозяйство КФХ Баранов А.Ю. расположено в Юргинском муниципальном районе. Хозяйство занимается производством зерновых, кормовых культур, а также продукцией животноводства. Тракторный парк оборудован системой Trimble EZ-Guide 250, планируется в дальнейшем перейти на систему автопилотирования EMD на базе монитора CFX -750. Прикладных программ по учету и прогнозированию урожая не используется, но планируется. Имеется Комбайн ACROS 585 плюс с бортовой информационной системой Adviser II. Анализ почв проводится в ООО «Центр передового земледелия» КАО «Азот».

Предприятие ООО КДВ Агро, Яшкинский муниципальный район: на технике установлено оборудование и программное обеспечение АвтоГРАФ для мониторинга транспорта и персонала, обеспечивает контроль топлива. В хозяйстве применяют прикладную программу по учету и прогнозированию урожая – система управления агропроизводством Cropio – система дистанционного контроля сельскохозяйственных угодий, которая включает оперативный мониторинг состояния посевных площадей,

документирование прогнозирование и планирование хозяйственных операций. Анализ почв проводится в ООО «Центр передового земледелия» КАО «Азот».

Таким образом, практическое использование точного земледелия осуществляется в определённой последовательности. Первый шаг: устанавливаются границы полей, оцифровка полей посредством информационных технологий, включая космическую съемку. Далее производится картирование полей по урожайности сельскохозяйственных культур. Используя оптоэлектронные датчики (сенсоры) и оптические системы на уборочной технике, получаем информацию по урожайности культур с точной привязкой к координатам каждого отдельного участка на поле. Третий шаг – выявление проблемных участков по продуктивности агроценозов. Сбор информации о факторах почвенного плодородия позволяет формировать банк данных по водно- физическим, агрохимическим биологическим показателям плодородия, сгруппировать участки на поле по уровню плодородия. Четвертый шаг – оптимизация почвенных и фитосанитарных условий посевов для продуцирования агроценозов. В завершение проводится анализ применения технологий точного земледелия по оценке эффективности: по продуктивности агроценозов – агрономической; по влиянию на плодородие почвы – экологической; по рентабельности производства – экономической [2].

Заключение. Точные агротехнологии на сегодняшний день используют не только крупные сельхозтоваропроизводители. Анализ показал, что элементы точного земледелия широко применяются и на ведущих сельскохозяйственных предприятиях Кемеровской области, что способствует более эффективному использованию ресурсов, высокой урожайности культур и регулированию экологической нагрузки на почву.

Список литературы

1. Абрамов Н. В. Производительность агроэкосистем и состояние плодородия почв в условиях Западной Сибири / Н. В. Абрамов // Государственный аграрный университет Северного Зауралья. – Тюмень: ГАУ Северного Зауралья, 2013. – 254 с. URL: https://cyberleninka.ru (дата обращения: 08.10.2026).
2. Полухин А. А. Управление продукционными процессами агробиоценозов с применением космических систем / А. А. Полухин, В. И. Панарина, Н. В. Санникова и др. – Текст: электронный // Аграрная Россия. – 2021. – №12. – С. 21–25. – URL: cyberleninka.ru (дата обращения: 08.10.2026).

УДК 004.9.910.27

РАЗРАБОТКА АРХИТЕКТУРЫ ГЕОИНФОРМАЦИОННОЙ СИСТЕМЫ ПЕШЕХОДНОЙ НАВИГАЦИИ С УЧЁТОМ ФАКТОРОВ БЕЗБАРЬЕРНОЙ ГОРОДСКОЙ СРЕДЫ

Выпряжкина А.А., ORCID 0009-0005-8708-8870,
Филонова Е.С., ORCID 0009-0008-6809-9402
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
annaviyprazhkina@yandex.ru, hiccup@mail.ru

Аннотация. Рассмотрена проблема пешеходной навигации в городской среде. Проанализированы актуальные изменения на рынке навигационных сервисов в 2025–2026 годах. Предложена архитектура геоинформационной системы «Без преград», которая дополняет существующие картографические сервисы и строит маршруты с учётом индивидуальных ограничений мобильности пользователей.

Ключевые слова: геоинформационная система, пешеходная навигация, безбарьерная среда, доступность, PostGIS, OpenStreetMap, алгоритм Дейкстры, краудсорсинг, искусственный интеллект.

Введение. Современные цифровые навигационные сервисы не решают в полной мере проблему доступности городской среды для маломобильных групп населения. Яндекс.Карты, Google Maps, 2ГИС – ориентированы преимущественно на построение кратчайшего или наиболее быстрого маршрута и до недавнего времени не учитывали параметры, критически важные для пешеходов с ограниченными возможностями.

В 2025 году Яндекс.Карты начали добавлять информацию о доступности объектов инфраструктуры, а также учитывать пандусы при построении пешеходных маршрутов [1; 2]. В 2026 году сервис перешёл на автоматический анализ доступности с помощью нейросетей: две ИИ-модели – визуально-языковая Alice AI VLM и языковая Alice AI LLM – анализируют фотографии входов в организации, определяя наличие пандусов, поручней, ширину проходов и высоту порогов. Программа «Доступная среда» продлена до 2030 года, однако инструментов динамического мониторинга доступности городской инфраструктуры по-прежнему недостаточно [3].

Цель работы – разработка архитектуры геоинформационной системы пешеходной навигации, учитывающей факторы безбарьерной городской среды и допускающей коллективное пополнение данных пользователями.

Основная часть. Предлагаемая система «Без преград» работает поверх существующих картографических сервисов и добавляет к ним

тематический слой доступности. Архитектура, представленная на рисунке, включает пять компонентов: пользовательский интерфейс, серверную часть, базу пространственных данных, картографическую основу и модуль расчёта маршрутов



Рис. Архитектура геоинформационной системы «Без преград»

Пользователь с помощью интерактивной карты (голосового помощника) указывает начальную и конечную точки, выбирает профиль доступности (колясочник, родитель с коляской, курьер, турист и т.д.) и получает оптимальный путь. Отдельный веб-интерфейс предназначен для организаций: администраций, вузов, больниц, торговых центров.

Серверная часть обрабатывает запросы, связывает функциональные модули и передаёт актуальные данные клиенту.

База пространственных данных строится на PostgreSQL с расширением PostGIS [4]. Картографическая основа формируется на базе OpenStreetMap, предоставляющей открытые данные о дорожной сети. Поверх неё накладывается тематический геоинформационный слой доступности – ключевое отличие системы от существующих навигаторов.

Модуль расчёта маршрутов представляет пешеходную сеть в виде графовой модели. Расчёт выполняется алгоритмами поиска кратчайшего пути – Дейкстры или A* [5].

Коллективное пополнение данных. Пользователь отмечает на карте обнаруженный объект, указывает тип, местоположение, описание и при необходимости прикрепляет фотографию. Сведения поступают на сервер, проходят проверку на корректность и дублирование, после чего включаются в тематический слой. Подобный механизм краудсорсинга уже показал эффективность: в Яндекс.Картах данные о пандусах собирали «полевые пешеходы» и активные пользователи Народной карты.

Роль искусственного интеллекта. Нейросеть распознаёт препятствия по фотографиям, а NLP-модель классифицирует текстовые сообщения пользователей и назначает категорию и приоритет. Автоматически выявленные препятствия проходят проверку, поскольку ИИ может ошибаться. Опыт Яндекс.Карт 2026 года показывает, что двухступенчатая схема – визуальная модель плюс языковая – позволяет автоматизировать разметку миллионов фотографий.

Перспективы развития. Тематический слой доступности может использоваться в партнёрских проектах с навигационными платформами, службами доставки и муниципальными организациями. Это расширяет охват территории и повышает практическую ценность собранных данных.

Заключение. В работе предложена архитектура геоинформационной системы пешеходной навигации, ориентированной на учёт факторов безбарьерной городской среды. Система поддерживает пополнение геоинформационной базы пользователями, дополняет актуальные решения современных навигационных сервисов специализированным слоем доступности и персонализированной маршрутизацией. Дальнейшая работа предполагает разработку прототипа, формирование базы пространственных данных и экспериментальную оценку качества маршрутов на выбранном городском участке.

Информация о финансовой поддержке: *исследование проводится в рамках инициативного студенческого проекта.*

Список литературы

1. Яндекс Карты теперь учитывают 40 тысяч пандусов при построении пешеходных маршрутов в городах России: электронный ресурс // Яндекс: официальный сайт. – 2025. – 12 февраля. – URL: https://www.yandex.ru/company/news/01-12-02-2025 (дата обращения: 30.09.2026).
2. Яндекс Карты добавили 120 тыс. отметок о доступности мест маломобильным людям: данные обновляет ИИ – автоматически: электронный ресурс // RB.RU – 2026. – 5 июня. – URL: https://rb.ru/news/yandeks-karty-dobavili-120-tys-otmetok-o-dostupnosti-mest-malomobilnym-lyudyam-dannye-obnovlyaet-ii-avtomaticheski/ (дата обращения: 30.09.2026).
3. План мероприятий по повышению эффективности госпрограммы «Доступная среда». // Министерство труда и социальной защиты Российской Федерации: официальный сайт. – 2017. – Текст: электронный. – https://mintrud.gov.ru/docs/1281 (дата обращения: 30.09.2026).
4. PostGIS Project. PostGIS Documentation. – URL: https://postgis.net/documentation/ (дата обращения: 30.09.2026).
5. Hart P. E. A Formal Basis for the Heuristic Determination of Minimum Cost Paths / P. E. Hart, N. J. Nilsson, B. Raphael // IEEE Transactions on Systems Science and Cybernetics. – 1968. – Vol. 4, № 2. – P. 100–107.

УДК 664, 721.021.23

ГЕНЕРАТИВНОЕ МОДЕЛИРОВАНИЕ В ИНЖИНИРИНГЕ СОСТАВА ПИЩЕВЫХ ПРОДУКТОВ

Галатов С.А.[1], Россинская М.В.[2], д-р экон. наук, проф.
[1]ФГБОУ ВО «Российский биотехнологический университет», г. Москва, РФ,
[2]АНОВО «Московский международный университет», г. Москва, РФ
stepangalatov@mail.ru, rossmv@mail.ru,

Введение. Разработка новых пищевых продуктов остаётся преимущественно эмпирическим процессом, в котором подбор рецептуры опирается на опыт технолога и многократные лабораторные тестирования. Традиционный подход остаётся трудоёмким, длительным и слабо воспроизводимым. Генеративные модели позволяют автоматизировать этот этап [1]. В статье оценивается потенциал генеративных моделей для автоматизированного формирования рецептур с заданными ограничениями.

Обычно классические методы оптимизации состава пищевых продуктов опираются на линейное программирование, эксперименты и лабораторный анализ. Они помогают технологам решить проблемы оптимизации пищевой ценности и стоимости. Однако данные методы имеют ряд ограничений, например линейность моделей или недостаток баз данных ингредиентов [2]. Инновационным в пищевой промышленности также является машинное обучение, которое чаще всего представлено моделями-предикторами для прогнозирования текстуры, вкусовых качеств и пищевой ценности по новому составу и технологическим параметрам [3].

Методология. В рамках генеративного моделирования рецептура продукта представляет собой особый вектор в матрице ингредиентов. Компонентами рецептуры являются массовые доли, технологические параметры и прочие ограничения. Целевая функция процесса моделирования – это объединение основных критериев либо в скалярный показатель качества, либо во множество ограничений. В данном иследовании были рассмотрены следующие генеративные модели:

– модель-VAE, которая применяется для сжатия всех возможных рецептур и проведения сравнений между успешными экземплярами;

– условный GAN, который используется для направленной генерации под заданные целевые характеристики: генератор формирует вектор рецептуры, обусловленный вектором целевых свойств; дискриминатор различает реальные и сгенерированные составы;

– диффузионные модели, внедряемые для поэтапного уточнения рецептуры с целью перехода к оптимальному варианту, что позволяет управлять балансом новизны и целесообразности в рецептуре;

– LLM-подход, который служит для поиска альтернативных ингредиентов и их текстового описания и представляет собой модель,

обученную на основе имеющихся рецептур и технологических спецификаций, которая способна предлагать альтернативные компоненты с учётом свойств тех или иных продуктов питания.

Обучение генеративных моделей обычно проводится на выборке рецептур из заданной или собранной из баз данных продуктов категории, основанной на результатах сенсорных панелей и внутренних данных производителя. Предобработка включает нормировку массовых долей, кодирование категориальных признаков и проверку физико-химической совместимости компонентов. Для каждой модели формируется обучающее и валидационное подмножества в соотношении 80:20. Качество генерации оценивается на отложенной выборке.

Эксперимент. В качестве экспериментальной категории выбраны молочные десерты – продукт с многообразием текстур, разнообразием ингредиентов и хорошо структурированными данными составов. Модели обучались на 1200 рецептурах, включающих молочную основу, стабилизаторы, подсластители, ароматизаторы и функциональные добавки. Генерация новых составов проводилась под следующими целевыми ограничениями: снижение содержания сахара не менее чем на 30 % относительно базовой рецептуры, повышение белка до 6 г на 100 г продукта, себестоимость в пределах заданного лимита. Каждая архитектура генерировала по 200 кандидатов на состав. Оценка качества генераций проводилась по четырём критериям: физическая корректность, сенсорная валидность, новизна и оптимизационная эффективность. Схема эксперимента представлена на рисунке.

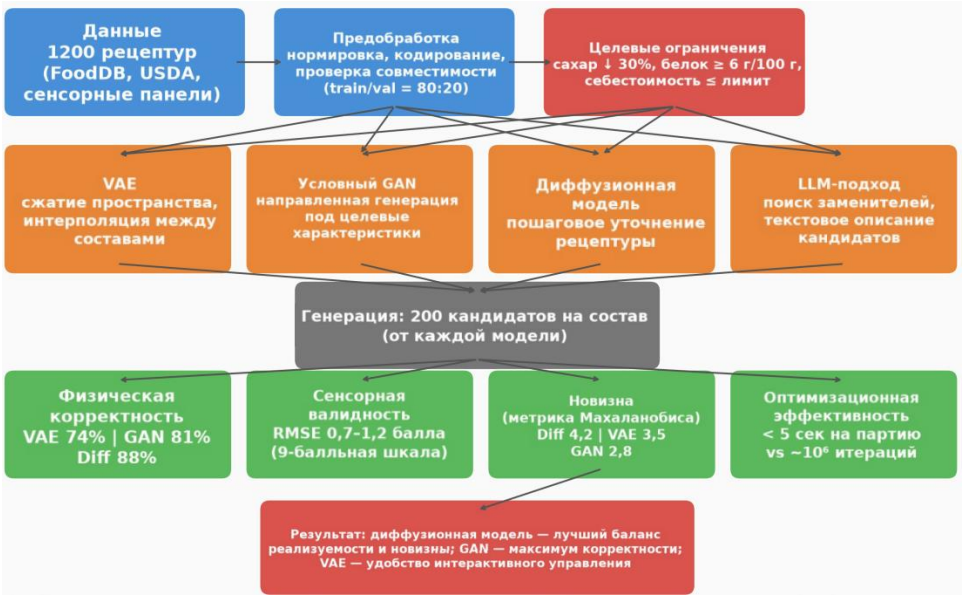


Рис. Схема проведения эксперимента по генеративному моделированию рецептур молочных десертов

Результаты. По данным эксперимента доля рецептур, которые возможны чисто физически, составила: VAE – 74 %, условный GAN –

81 %, диффузионная модель – 88 %. Предсказанные оценки сенсорных характеристик сравнивались с оценками технологов на 20 сгенерированных рецептурах каждой модели, при этом среднеквадратичная ошибка составила 0,7–1,2 балла по 9-балльной шкале. Диффузионная модель показала наибольшую новизну – 4,2, условный GAN – наименьшую 2,8, VAE занял промежуточное положение 3,5. Все модели формировали 200 рецептур менее чем за 5 секунд. Для сравнения, полный перебор данных по сетке с тем же шагом потребовал бы у технолога порядка 10^6 итераций.

Диффузионная модель показала наилучший баланс между физической реализуемостью и новизной генерируемых составов. Условный GAN обеспечил наивысшую долю физически корректных рецептур, но генерировал составы, близкие к обучающим данным, что ограничивает исследовательский потенциал. Модель-VAE продемонстрировала средние результаты по всем критериям. Но в то же время ее пространство удобнее для интерактивного управления составами продуктов, поэтому технологам будет проще выделять кластеры и задавать направление генерации состава вручную.

Ключевые ограничения подхода связаны с качеством обучающих данных. Проблема интерпретируемости остаётся нерешённой, так как модель не объясняет, почему выбран конкретный набор ингредиентов, что затрудняет принятие решения технологом. Риск генерации физически нереализуемых сочетаний требует обязательной проверки, например через симуляцию технологического процесса или лабораторные испытания.

Выводы. Регуляторные аспекты требуют отдельного внимания. Все сгенерированные составы должны соответствовать ТР ТС 021/2011 и отраслевым стандартам; новые ингредиенты или комбинации, не имеющие установленного допустимого уровня суточного потребления, подлежат дополнительной оценке безопасности. Поэтому генеративное моделирование пока применимо только как инструмент поддержки решений в инжиниринге пищевых продуктов.

Список литературы

1. Садовой В. В. Нейросетевая разработка рецептурных составов пищевых продуктов, и оценка качественных характеристик готовых изделий / В. В. Садовой, Т. В. Щедрина, А. С. Хамицаева и др. // Современная наука и инновации. – 2024. – №1. – С. 71–79. – DOI: 10.37493/2307-910X.2024.1.7.
2. Фролов Д. И. Проектирование рецептур с помощью искусственного интеллекта / Д. И. Фролов, М. А. Сергеева // Информационные технологии в индустрии. – 2023. – №2. – С. 37-43.
3. Галатов С. А. Роботизация процессов приготовления пищи: современные решения и перспективы внедрения / С. А. Галатов // Цифровое общество: образование, экономика, технологии – 2026. – С. 309-314. – EDN HEAUTR.

УДК-004.85

МОДЕЛИРОВАНИЕ ВЕРОЯТНОСТИ ОТТОКА КЛИЕНТОВ ФИТНЕС-ОРГАНИЗАЦИИ С ПРИМЕНЕНИЕМ МАШИННОГО ОБУЧЕНИЯ

Галимов Б.Р.,
Сибаева Г.Р., канд. экон. наук, доц., ORCID 0000–0002–0747–4474
ФГБОУ ВО «Казанский государственный энергетический университет», г. Казань, РФ
bulatgalimov96@gmail.com, sibaeva.gr@kgeu.ru

Аннотация. В статье экспериментально оценено применение методов машинного обучения для прогнозирования оттока клиентов фитнес-организаций: на синтетическом датасете наилучшие результаты продемонстрировала сбалансированная логистическая регрессия, позволив выделить группу риска и сократить расчетные трудозатраты.

Ключевые слова: искусственный интеллект; машинное обучение; отток клиентов; логистическая регрессия; случайный лес; прогнозирование.

Введение. Удержание клиентов – ключевой фактор устойчивости фитнес-индустрии. Методы машинного обучения (ML) позволяют прогнозировать отток на основе поведенческих паттернов [1-5]. Однако из-за разнообразия алгоритмов и метрик сопоставимость их эффективности часто ограничена спецификой данных [6], несмотря на доминирование на практике логистической регрессии (Logistic Regression – метод классификации, оценивающий вероятность принадлежности объекта к классу.) и случайного леса (Random Forest – ансамблевый метод машинного обучения) [7].

Исследование выполнено на синтетическом наборе из 2000 клиентов. Решается задача бинарной классификации для оценки вероятности оттока p(churn=1|x) на основе поведенческих (история и динамика посещений) и демографических данных, где x – вектор этих характеристик, а churn=1 – индикатор оттока.

Экспериментальная процедура. Синтетическая выборка разделена на обучающую и тестовую части в соотношении 70:30. Моделирование выполнено в библиотеке scikit-learn. Для сравнения выбраны три алгоритма: стандартная логистическая регрессия, логистическая регрессия с балансировкой классов и случайный лес. Качество оценивается по Accuracy (доле правильных классификаций), Precision (доле действительно положительных объектов среди объектов, отнесенных моделью к положительному классу), Recall (доле выявленных моделью положительных объектов среди всех фактически положительных объектов), F1-score (гармоническому среднему Precision и Recall) и ROC-

AUC (показателю способности модели разделять классы по различным порогам классификации).

Для задачи удержания особое значение имеет Recall, поскольку FN соответствует пропуску клиента, который фактически ушел. Поэтому выбор модели не должен основываться только на Accuracy. В исследованиях оттока клиентов также рекомендуется учитывать совокупность метрик и бизнес-постановку задачи [6].

Результаты тестирования трех моделей представлены в таблице.

Таблица

Результаты сравнения моделей на тестовой выборке

Модель	**Accuracy**	**Precision**	**Recall**	**F1**	**ROC-AUC**	**Threshold**
Logistic Regression	76,17 %	64,00 %	37,43 %	47,23 %	78,67 %	0,29
Logistic Regression Balanced	71,33 %	49,81 %	74,85 %	59,81 %	78,63 %	0,49
Random Forest	71,67 %	50,21 %	70,18 %	58,54 %	77,56 %	0,47

Для приоритизации работы с клиентами выбрана модель Logistic Regression Balanced, показавшая на тестовой выборке Recall 74,85 %, F1 59,81 % и ROC-AUC 78,63 % (снижение Accuracy обусловлено коррекцией дисбаланса классов). Применение модели к полной базе из 2000 клиентов сформировало группу высокого риска из 882 человек (44,10 %), в которую вошли 426 из 571 фактически ушедших (Recall 74,61 %, Precision 48,30 %). Модель охватывает значительную часть оттока, однако наличие ложноположительных прогнозов требует участия сотрудника.

До применения модели бизнес-процесс включает «вся база клиентов − ручной анализ − определение возможного риска − связь с клиентом». При использовании ML он изменяется на «вся база − обработка данных − ML-модель − вероятность оттока − группа высокого риска − приоритетная работа сотрудника». ML-компонент выполняет предварительную сортировку клиентской базы перед взаимодействием с клиентом.

Роль сотрудника сохраняется: модель не определяет автоматически действие в отношении клиента. Ее назначение − сократить объем первичного анализа.

Сценарная оценка трудозатрат. Для иллюстрации изменения трудозатрат задан сценарий: ручной анализ одного клиента занимает 2 мин., работа с клиентом из группы высокого риска − 3 мин. При полном анализе 2000 клиентов расчетное время составляет 4000 мин.: 2000 × 2 = = 4000 мин. При работе с группой высокого риска из 882 клиентов расчет составляет: 882 × 3 = 2646 мин. Разница составляет 1354 (4000 − 2646) мин., а относительное сокращение расчетного объема работы − 33,85 % (1354 / 4000 × 100%). Показатель является сценарной оценкой при заданных предположениях.

Полученные результаты соответствуют общей логике исследований оттока клиентов: машинное обучение может использоваться для оценки вероятности ухода и формирования целевой группы для последующих удерживающих действий [6, 7].

Для фитнес-контекста важны поведенческие характеристики. Исследования фитнес-центров связывают посещаемость и последовательность использования услуги с удержанием членов клуба [3, 4]. Вместе с тем факторы удержания шире посещаемости: российские исследования выделяют отраслевые и маркетинговые факторы, включая сегментацию и клиентскую ориентированность [4]. Исследования рынка фитнес-услуг подтверждают актуальность анализа состояния отрасли и перспектив ее развития [5].

Практически важен баланс между полнотой выявления оттока и числом клиентов, требующих внимания сотрудника. В эксперименте сбалансированная логистическая регрессия дает высокий Recall, но Precision ниже 50 %. Поэтому группу нельзя трактовать как автоматический список «ушедших клиентов»; корректнее рассматривать ее как список повышенного риска для дополнительной проверки [3].

Заключение. В работе проведено экспериментальное моделирование удержания клиентов фитнес-организации методами машинного обучения. Ее применение позволило сформировать группу риска из 882 человек, что в сценарном расчете обеспечило сокращение трудозатрат на 33,85 %. Ключевой результат – воспроизводимая схема интеграции ML в бизнес-процессы, где модель выступает инструментом поддержки решений, а не заменой сотрудника. Следующий этап – валидация подхода на реальных данных, оптимизация порога классификации и оценка фактического экономического эффекта.

Список литературы

1. Сибаева Г. Р. Разработка интеллектуальной пропускной системы / Г. Р. Сибаева // Мягкие измерения и вычисления. – 2026. – Т. 100, № 3-3. – С. 42-48. – DOI 10.36871/26189976.2026.03-3.005. – EDN ALMVZU.
2. Мануйленко Э. В. Использование технологий искусственного интеллекта в спорте / Э. В. Мануйленко и др // Экономика и управление в спорте. – 2025. – Т. 5, № 1. – С. 99-112. – DOI 10.18334/sport.5.1.121234. – EDN WURNHI.
3. Богдан Н. В. Оценка потребностей клиентов фитнес-услуг на Южном Урале / Н. В. Богдан, Г. Н. Пряхин // Экономика и управление в спорте. – 2024. – Т. 4, № 2. – С. 95-106. – DOI 10.18334/sport.4.2.120873. – EDN VPLWBA.
4. Фахретдинова А. Б. Маркетинговые тактики и инструменты в практике управления продвижением малой физкультурно-спортивной организации / А. Б. Фахретдинова, Т. Е. Блиновская // Экономика и управление в спорте. – 2024. – Т. 4, № 1. – С. 27-44. – DOI 10.18334/sport.4.1.120340. – EDN IROPAS.
5. Сибаева Г. Р. Модуль учета ресурсов организации в рамках перехода на отечественные решения / Г. Р. Сибаева, В. А. Беляев, Е. С. Лазарев // Экономика и управление: проблемы, решения. – 2025. – Т. 12, № 2(155). – С. 29-35. – DOI 10.36871/ek.up.p.r.2025.02.12.005. – EDN MOYYJH.

6. Manzoor A. A Review on Machine Learning Methods for Customer Churn Prediction and Recommendations for Business Practitioners / Manzoor A., Qureshi M.A., Kidney E. [et al.] // IEEE Access. – 2024. – Vol. 12. – P. 70434–70463. – DOI: 10.1109/ACCESS.2024.3402092.
7. Sikri A. Enhancing customer retention in telecom industry with machine learning driven churn prediction / A. Sikri, R. Jameel, S. M. Idrees [et al.] // Scientific Reports. – 2024. – Vol. 14. – Article 13097. – DOI: 10.1038/s41598-024-63750-0.

УДК 004.93:616.5

ВЛИЯНИЕ ГЕОМЕТРИЧЕСКИХ ПАРАМЕТРОВ АУГМЕНТАЦИИ НА УСТОЙЧИВОСТЬ ПРИЗНАКОВ ГИБРИДНОЙ МОДЕЛИ CNN-RANDOM FOREST ПРИ БИНАРНОЙ КЛАССИФИКАЦИИ НОВООБРАЗОВЫАНИЙ КОЖИ

Ганциевский А.В., доц., ORCID 0009-0003-7162-0450,
Белоусова В.С., 0009-0007-2498-3733
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
gantsievskii@sfedu.ru, viktoria.belousova.work@yandex.ru

Введение. Подход к диагностике и лечению в дерматовенерологии значительно изменился с появлением новых технологий и изобретений. Компьютерные алгоритмы нашли свое применение в оказании помощи дерматовенерологам в диагностике заболеваний, в том числе злокачественной меланомы кожи. Инструментальные методы диагностики меланомы кожи, основанные на обработке дерматоскопических изображений, могут быть усовершенствованы путем использования искусственного интеллекта. Машинное обучение – это подмножество искусственного интеллекта, в котором компьютерные программы автоматически учатся на опыте без явных инструкций для работы. Наиболее перспективным направлением является глубокое обучение искусственных нейронных сетей [2].

Раннее выявление меланомы обеспечено эффективными инструментами, но их доступность неравномерна. Дерматоскопия даёт наибольшую чувствительность, однако требует оборудования и квалификации, которыми располагает не каждое учреждение. В результате значительная часть случаев выявляется на поздних стадиях. Альтернативой выступают мобильные системы поддержки врачебных решений: анализ снимков со смартфона гибридными нейросетевыми архитектурами. Они демонстрируют точность, сопоставимую с классическими свёрточными сетями, а иногда и превосходящую их. Но перенос модели в клиническую практику упирается не столько в архитектуру, сколько в устойчивость признакового пространства: модель обязана сохранять диагностически значимые

характеристики независимо от положения, ориентации и масштаба новообразования в кадре.

Основной инструмент формирования такой инвариантности – геометрическая аугментация. Но здесь возникает парадокс: чрезмерная инвариантность достигается ценой размывания клинически значимых различий. Асимметрия, неровность границ, пропорции новообразования сами по себе являются диагностическими критериями. Цель исследования заключается в установлении диапазонов геометрических преобразований, при которых достигается баланс между инвариантностью эмбеддингов и сохранением их дискриминативной способности.

Основная часть. Исследование было выполнено на объединённой выборке: публичный дерматологический датасет HAM10000 и собственные клинические наблюдения [1]. Задача состояла в бинарной классификации: доброкачественные образования в один класс, злокачественные в другой. Схема включала два этапа: предобученная свёрточная сеть формировала векторное представление снимка, которое затем подавалось на вход ансамблю решающих деревьев.

Геометрические преобразования применялись только к обучающей части выборки, валидационные и тестовые снимки оставались исходными, что позволило исключить утечку информации. Варьировались угол поворота, величина сдвига, коэффициент масштабирования и вероятность горизонтального отражения. При этом фиксировались точность, F1-мера, внутриклассовая и межклассовая дисперсия эмбеддингов, а также их проекция методом t-SNE.

Исследование показало, что обучение без преобразований дало 84,2 % точности при разрыве обучение/валидация 9,0 %, что указывает на переобучение. Умеренные преобразования изменили картину следующим образом: поворот ±25° поднял точность до 88,7 %, сдвиг до 10 % – до 88,1 %. Совместное применение умеренного поворота и сдвига дало лучший результат в 89,3 % при сокращении разрыва до 3,1 %.

Визуализация t-SNE показала, что при таких параметрах кластеры доброкачественных и злокачественных эмбеддингов становятся компактнее и отстоят дальше друг от друга. Умеренные преобразования заставляют сеть формировать представления, инвариантные к положению и ориентации объекта, не разрушая его внутреннюю структуру.

Обратная закономерность проявилась при избыточных преобразованиях: поворот ±45° снизил точность до 83,5 %, масштабирование [0,7; 1,3] до 82,8 %, то есть ниже базового уровня. Причина в природе ансамбля деревьев: разбиение пространства признаков в Random Forest идёт по осям, и систематическое искажение геометрии эмбеддингов нарушает ориентацию разделяющих границ. Клинически значимые характеристики, такие как асимметрия, характер границ, пропорции, смешиваются с артефактами, и деревья теряют способность к дискриминации.

Горизонтальное отражение само по себе не ухудшило точность (84,5 %), но в сочетании с интенсивными поворотами усиливало деградацию. Анализ важности признаков подтвердил наличие оптимального диапазона: при умеренной аугментации растёт вклад контурных и текстурных дескрипторов, при избыточной их значимость снижается. Сводные результаты экспериментов представлены в таблице.

Таблица

Влияние геометрических параметров аугментации на точность гибридной модели CNN + Random Forest

Параметр аугментации	Диапазон	Точность, %	F1-мера	Разрыв обучение/валидация, %
Без аугментации	-	84,2	0,831	9,0
Поворот	±10°	86,4	0,855	6,2
Поворот	±25°	88,7	0,879	4,1
Поворот	±45°	83,5	0,821	8,7
Сдвиг	5%	86,1	0,852	6,5
Сдвиг	10%	88,1	0,873	4,3
Сдвиг	20%	84,8	0,836	7,9
Масштабирование	[0,9; 1,1]	87,2	0,864	5,0
Масштабирование	[0,8; 1,2]	88,5	0,877	4,2
Масштабирование	[0,7; 1,3]	82,8	0,814	9,4
Отражение	p = 0,5	84,5	0,834	8,8
Комбинация умеренных	±25°, 10%, [0,8; 1,2]	89,3	0,886	3,1

Заключение. Геометрическая аугментация в гибридной модели CNN + Random Forest подчиняется принципу оптимума: существует диапазон преобразований, в котором инвариантность эмбеддингов растёт быстрее, чем теряется их информативность. Для поворота этот диапазон ограничен ±25°, для сдвига – 10 %, для масштабирования – [0,8; 1,2]. Выход за эти пределы приводит к разрушению клинически значимых характеристик и снижению точности ниже базового уровня. Комбинирование умеренных преобразований даёт наибольший эффект в 89,3% точности при разрыве обучение/валидация 3,1 %.

Полученные результаты задают регламент геометрической предобработки для систем мобильной дерматоскопии и указывают на необходимость учитывать чувствительность классификатора к ориентации признакового пространства.

Список литературы

1. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions – ViDIR Dataverse [Electronic resource]. Accessed: 06.11.22. URL:https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/DBW86T (дата обращения: 05.10.2026).
2. Кошечкин К. А. Подбор модели нейронной сети для раннего обнаружения меланомы кожи / К. А. Кошечкин, А. А. Игнатьев, Н. В. Фриго и др. // Клиническая

дерматология и венерология. – 2023. – №22(3). – С. 287-295. DOI: 10.17116/klinderma202322031287.
3. Милантьев С. А. Применение технологий нейронных сетей и компьютерного зрения для анализа изображений кожных новообразований / С. А. Милантьев, А. А. Кордюкова, Д. О. Шевяков и др. // Научно-технический вестник информационных технологий, механики и оптики. – 2022. – Т. 22. – № 5. – С. 859–865. DOI: 10.17586/2226-1494-2022-22-5-859-865.

УДК 004.8

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ФОРМИРОВАНИЯ РЕЛЕВАНТНОГО КОРПУСА НАУЧНЫХ ПУБЛИКАЦИЙ

***Дидур Д.А.*[1,2]**, ORCID 0009-0006-4283-2587,
***Максимова А.Ю.*[1]**, ORCID 0000-0001-9496-4385,
***Блохин С. В.*[2]**, ORCID 0009-0002-8330-0123
[1]ФГБНУ «Институт прикладной математики и механики», г. Донецк, РФ
[2]ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
didurdiana7@gmail.com, maximova.alexandra@mail.ru, bsvtsu@mail.ru

Введение. Рост числа научных публикаций усложняет отбор источников для научного анализа. RAG-системы дополняют языковые модели внешними знаниями [1], GraphRAG представляет сущности и связи между ними в виде графа [2], а RAGU использует многоэтапное извлечение и консолидацию графа знаний [3]. Однако эти подходы преимущественно работают с уже сформированным корпусом, тогда как предварительный отбор и динамическое обновление публикаций требуют отдельного решения. Цель исследования – разработать математическую модель формирования релевантного корпуса на основе семантического и терминологического соответствия.

Основная часть. Пусть T – тема исследования, t – текущий момент времени, P_t – множество уникальных публикаций после приведения метаданных к единому формату и устранения дубликатов (нормализации). Требуется сформировать рабочий корпус $P_t^{pab} \subseteq P_t$ для последующей обработки полных текстов и построения графа знаний.

Семантическое соответствие публикации теме первоначально оценивается по названию и аннотации с использованием косинусного сходства векторных представлений [4, 5]. Предварительная оценка $C_{\text{смысл}}^{(0)}(p_k, T)$ может уточняться по фрагментам полного текста при его наличии:

$$C_{\text{смысл}}(p_k, T) = \mu C_{\text{смысл}}^{(0)}(p_k, T) + (1 - \mu) C_{\text{текст}}(p_k, T) \qquad (1)$$

где $C_{\text{смысл}}^{(0)}(p_k, T)$– предварительная оценка по названию и аннотации; $C_{\text{текст}}(p_k, T)$ – оценка по релевантным фрагментам полного текста; $\mu \in [0,1]$ – коэффициент относительного вклада предварительной оценки.

Смысловая близость дополняется терминологической оценкой. Для темы T формируется множество значимых терминов $E_t(T)$, включающее названия методов, алгоритмов, моделей, наборов данных и специальные научные понятия. Для каждого термина вводится индикатор $I_l(p_k)$, а a_l задаёт его значимость. Терминологическое соответствие определяется как:

$$C_{\text{терм}}(p_k, T) = \frac{\sum_{l=1}^{L_t} a_l I_l(p_k)}{\sum_{l=1}^{L_t} a_l} \quad (2)$$

Значения a_l определяют важность терминов и задаются экспертно или по размеченной выборке публикаций с оценками релевантности теме T. Терминологическое соответствие учитывается совместно с семантическим сходством.

Для предварительного отбора общая тематическая релевантность объединяет семантическую оценку по названию и аннотации с терминологическим соответствием:

$$R(p_k, T) = w_1 C^{(0)}_{\text{смысл}}(p_k, T) + w_2 C_{\text{терм}}(p_k, T) \quad (3)$$

где w_1 и w_2 – неотрицательные весовые коэффициенты, w_1+w_2=1; их значения настраиваются экспериментально.

При пороге $\tau_{\text{рел}}$ рабочий корпус образуют публикации, прошедшие предварительный отбор и удовлетворяющие условию:

$$P_t^{\text{раб}} = \{p_k \in P_t^0 | R(p_k, T) \geq \tau_{\text{рел}}\} \quad (4)$$

Порог $\tau_{\text{рел}}$ и весовые коэффициенты определяются по выборке публикаций с экспертными оценками релевантности. Пограничные случаи могут дополнительно проверяться языковой моделью по названию и аннотации.

Актуальность публикации оценивается отдельно с учётом её возраста Δt_k и параметра H, зависящего от научной области:

$$F(p_k, t) = 2^{-\frac{\Delta t_k}{H}}, 0 < F \leq 1 \quad (5)$$

Формула (5) даёт приближённую оценку актуальности и не определяет научную значимость публикации.

Качество доступных данных, отличное от научного качества публикации, определяется по показателям $K_{\text{метад}}$ – полнота метаданных, $K_{\text{дост}}$ – доступность полного текста, $K_{\text{стат}}$ – статус публикации (статья или препринт):

$$K_{\text{кач}}(p_k, t) = \alpha_1 K_{\text{метад}}(p_k, t) + \alpha_2 K_{\text{дост}}(p_k, t) + \alpha_3 K_{\text{стат}}(p_k, t) \quad (6)$$

Коэффициенты $\alpha_i \geq 0$, α_1+α_2+α_3=1 задаются экспертно или экспериментально; показатель отражает качество доступных данных, а не достоверность научных выводов.

Научная значимость $Z(p_k,t)$ оценивается по цитируемости, связям с другими исследованиями и подтверждению результатов.

Таким образом, R определяет релевантность, F – актуальность, $K_{\text{кач}}$ – качество данных, Z – научную значимость.

При обновлении корпуса новые публикации проверяются на дубликаты и релевантность, а неизменённые не обрабатываются повторно.

Отклонённые работы сохраняются для возможного пересмотра.

Графовая обработка по RAGU [3] выполняется для отобранных публикаций с доступным полным текстом. Динамическое формирование корпуса – самостоятельное дополнение к RAGU.

Для проверки модели используется размеченная выборка, разделённая на обучающую и тестовую части. На первой определяются w_1, w_2 и $\tau_{рел}$, на второй оцениваются Precision, Recall и F_1-мера. Новые публикации обрабатываются без повторной разметки при сохранении темы и качества отбора.

Заключение. Предложена математическая модель формирования и обновления релевантного корпуса научных публикаций на основе семантического и терминологического соответствия. Актуальность, качество данных и научная значимость учитываются отдельно. В отличие от прямой LLM-классификации, модель применяет явные критерии и повторно используемые параметры; сравнительная эффективность требует экспериментальной проверки.

Информация о финансовой поддержке: *Работа выполнена при финансовой поддержке Минобрнауки России в рамках научной темы «Разработка и совершенствование интеллектуальных методов классификации и прогнозирования для задач распознавания образов и моделирования информационных процессов» FREM-2024-0001 (регистрационный номер 1023111000141-9-1.2.1).*

Список литературы

1. Lewis P. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks / P. Lewis, E. Perez, A. Piktus [et al.]// Advances in Neural Information Processing Systems. – 2020. – Vol. 33. – P. 9459–9474.
2. Edge D. From Local to Global: A Graph RAG Approach to Query-Focused Summarization / D. Edge, H. Trinh, N. Cheng [et al.]. – 2024. – Текст электронный. – arXiv:2404.16130. – URL: https://arxiv.org/abs/2404.16130 (дата обращения: 05.10.2026). – DOI 10.48550/arXiv.2404.16130.
3. Komarov M. RAGU: A Multi-Step GraphRAG Engine with a Compact Domain-Adapted LLM / M. Komarov, I. Bondarenko, S. Shtuka [et al.]. – 2026. – Текст: электронный. – arXiv:2607.11683. – URL: https://arxiv.org/abs/2607.11683 (дата обращения: 05.10.2026). – DOI 10.48550/arXiv.2607.11683.
4. Reimers N. Sentence-BERT: Sentence Embeddings Using Siamese BERT-Networks / N. Reimers, I. Gurevych // Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). – 2019. – P. 3982–3992. – DOI 10.18653/v1/D19-1410.
5. Karpukhin V. Dense Passage Retrieval for Open-Domain Question Answering / V. Karpukhin, B. Oğuz, S. Min [et al.] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). – 2020. – P. 6769–6781. – DOI 10.18653/v1/2020.emnlp-main.550.

УДК 004.032.26

РАЗРАБОТКА ГИБРИДНОЙ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗА РИСКОВ ПРОВАЛООБРАЗОВАНИЯ

Дрибан В.А., д-р техн. наук, Scopus ID: 55963516100,
Яркова А.И., ORCID 0009-0001-4755-3732,
Антипенко А.В., ORCID 0009-0004-4102-054X,
Трофимов В.В., канд. техн. наук, ORCID 0009-0008-9955-3102,
Дуброва Н.А., канд. техн. наук, ORCID 0000-0003-2197-902X
ФГБНУ «Республиканский академический научно-исследовательский и проектно-конструкторский институт горной геологии, геофизики, геомеханики и маркшейдерского дела», г. Донецк, РФ
viktor-driban@yandex.ru, *yarkova_maths@mail.ru, ministrxp@mail.ru, victor.trofymov@ranimi.org, dubrovan@mail.ru*

Введение. В настоящее время аналитических моделей, способных надёжно предсказывать время провала, не существует. В связи с этим нейронные сети, обладающие способностью выявлять скрытые зависимости в данных, представляются наиболее перспективным инструментом для решения подобной задачи. При этом особое значение имеет учёт временной динамики, что делает целесообразным применение методов анализа выживаемости. [1].

Цель – построение и обучение нейросетевой модели на основе анализа выживаемости, способной с достаточной точностью предсказывать риск провалообразования над горными выработками.

Основная часть. Для обучения модели предварительно был сформирован набор данных, содержащий различные параметры выработок. В качестве входных признаков были зафиксированы: марка угля, коэффициент остаточного разрыхления, влияние горных работ, влияние обводнённости, техногенный фактор, наличие слабых грунтов в кровле, угол наклона выработки, влияние соседних выработок. В процессе обучения модели анализа выживаемости использовались также факт наступления события и время наблюдения.

Перед обучением данные были очищены, приведены к числовому формату, нормированы и вручную разделены на обучающую, валидационную и тестовую выборки для сохранения баланса признаков. Размер выборки изменялся по мере проведения исследования и подбора материалов. Всего в итоговой выборке оказалось 660 объектов: 142 случая с зарегистрированным провалом и 518 цензурированных наблюдений.

Распределение данных следующее:

- выработки с провалами – обучающая выборка: 100 случаев, валидационная: 30, тестовая: 12;
- выработки без провалов – обучающая выборка: 362 случая, валидационная: 114, тестовая: 42.

На первом этапе были протестированы различные модели анализа выживаемости. При небольшом объёме данных наилучшие результаты продемонстрировала дискретная архитектура PMF, позволившая получить первые оценки временной динамики. Однако с ростом выборки и увеличением доли цензурированных наблюдений проявились ограничения дискретного подхода: высокая чувствительность к выбору временной сетки, слабая способность к экстраполяции (невозможность выхода за пределы временного диапазона обучающей выборки), а также недостаточная дифференциация объектов по уровню риска.

Таким образом, дальнейшее развитие модели потребовало перехода к непрерывному подходу. В качестве основной архитектуры была выбрана модель Deep Survival Machines (DSM) [2]. Это полностью параметрическая модель анализа выживаемости, в которой время наступления события моделируется как смесь нескольких распределений (Вейбулла или логнормального), а нейросеть предсказывает параметры этих распределений и веса смеси. Функция потерь формируется на основе функции правдоподобия, при этом в неё введён дополнительный коэффициент, позволяющий снизить влияние цензурированных наблюдений.

Для выбора оптимальной структуры модели был применён генетический алгоритм, перебирающий комбинации гиперпараметров: число нейронов в скрытых слоях, количество компонент смеси, скорость обучения, размер батча, вес цензурированных данных в функции потерь. Итоговая модель DSM была выбрана по результатам работы алгоритма как имеющая наименьшее значение функции приспособленности. Выбранная модель имеет два скрытых слоя, содержащих 32 и 56 нейронов. Используются скорость обучения 0.005, размер батча 8 и смесь из двух компонент, основанных на распределении Вейбулла. Вес цензурированных объектов в функции потерь составляет 0.3, что позволило улучшить качество прогноза при устойчивой экстраполяции и корректном ранжировании объектов по степени риска.

Результаты показали высокую эффективность модели: средняя абсолютная ошибка прогноза времени провала составила около 10 лет, а индекс конкордации достигал 0,8. Построенные кривые выживания демонстрируют отчётливое различие между выработками, где провал произошёл, и теми, где он не наступил. Вместе с тем была выявлена систематическая переоценка времени наступления события, для снижения которой разработаны две модификации базовой модели.

Первая модификация основана на использовании кривой выживания. Из-за дисбаланса классов модель DSM завышает время наступления события, вследствие чего классические способы его определения – математическое ожидание или медиана – теряют свою эффективность. В полученных кривых выживания наблюдается резкое снижение вероятности в узком временном интервале, что позволяет интерпретировать этот

участок как зону повышенного риска. Время наступления события, таким образом, определяется по моменту достижения функцией выживания более высокого порога. Был протестирован ряд значений, и оптимальным оказался порог S(t) = 0.9. Именно это значение обеспечивает более консервативный прогноз и существенно снижает частоту переоценки времени наступления провала, что для решаемых задач является предпочтительным.

Вторая модификация основана на анализе остатков. Поскольку критичной ошибкой является переоценка времени, были рассмотрены только положительные разности между предсказанным и фактическим временем для объектов с наступившим событием. На основе диаграммы рассеяния была подобрана поправочная функция, основанная на плотности нормального распределения. После применения этой функции модель приобретает гибридный характер: нейронной сетью формируется базовый прогноз, который затем корректируется с учётом выявленного смещения.

Обе предложенные модификации продемонстрировали устойчивое снижение систематической переоценки времени наступления события, повысили согласованность предсказаний с реальными данными, и таким образом могут рассматриваться как инструменты оценки рисков при анализе провалоопасных территорий.

Заключение. Разработанные модели DSM достигли средней абсолютной ошибки порядка 10 лет и показали корректное ранжирование объектов по степени риска. Анализ кривых выживания подтвердил способность моделей выделять длительные интервалы устойчивости и формировать интерпретируемые прогнозы. Разработанные модификации позволили снизить систематическую переоценку времени наступления события для получения более реалистичных оценок.

Информация о финансовой поддержке. *Исследования проводились в рамках государственного задания (номер темы № FRSR-2024-0001).*

Список литературы

1. Дрибан В. А. Прогноз времени и вероятности образования провала земной поверхности над горными выработками с помощью нейросети / В. А. Дрибан, Н. А. Дуброва, В. В. Трофимов и др. // Физико-технические проблемы разработки полезных ископаемых. – 2026. – № 4. – С. 29-38. – DOI 10.15372/FTPRPI20260403.
2. Nagpal C. Deep Survival Machines: Fully Parametric Survival Regression and Representation Learning for Censored Data with Competing Risks / C. Nagpal, X. Li, A. Dubrawski // IEEE Journal of Biomedical and Health Informatics. – 2021. – Vol. 25(8). – P. 3163–3175.

УДК 004.05

К ВОПРОСУ ИНТЕГРАЦИИ ИИ В СИСТЕМЫ УПРАВЛЕНИЯ ИНФРАСТРУКТУРОЙ И БЕЗОПАСНОСТЬЮ В УНИВЕРСИТЕТЕ

Дунаев Р.А., канд. филос. наук, ORCID 0009-0003-0144-5976
ФГКОУ ВО «Белгородский юридический институт МВД России им И.Д. Путилина»,
г. Белгород, РФ
rmndnv@yandex.ru

Стремительное распространение ИИ трансформирует не только содержание образовательного процесса, но и подходы к управлению образовательными организациями. Особенно это актуально для современного университета, представляющего собой сложную цифровую среду. Вопрос, который возникает сегодня заключается уже не в том, будет ли использоваться ИИ в университете [1, с. 221], а в том, где его применение действительно дает измеримый эффект и как обеспечить его безопасное использование. В результате возникает принципиально новая задача, когда необходимо не просто внедрять отдельные технологии искусственного интеллекта, а определить, какие процессы университета действительно требуют интеллектуальной автоматизации и как сделать ее безопасной.

Одним из направлений развития такой среды является концепция «умного кампуса» (Smart Campus), которая предполагает объединение цифровых систем, устройств, данных и интеллектуальной аналитики. При этом ключевыми проблемами остаются интеграция разнородных систем, управление данными и информационная безопасность [2,3]. Для университета особенно важны процессы, в которых объем информации уже превышает возможности ее эффективной обработки человеком. В первую очередь это информационная безопасность, мониторинг цифровой инфраструктуры, техническая поддержка и анализ пользовательской активности. При этом ИИ не заменяет существующие средства защиты. Наиболее перспективным является их сочетание: традиционные правила и корреляция событий дополняются интеллектуальным анализом. Исследования систем обнаружения аномалий подтверждают возможности такого подхода, но одновременно указывают на проблемы ложных срабатываний и объяснимости решений [4].

Второе направление – интеллектуальная поддержка специалистов. Для сотрудника информационной безопасности или администратора проблема часто заключается не в отсутствии данных, а, наоборот, в их избытке. ИИ способен обработать большой объем информации, классифицировать события, найти взаимосвязи, сформировать краткое описание инцидента и предложить возможные действия. Исследования использования больших языковых моделей в центрах мониторинга

безопасности показывают, что они уже могут применяться как инструмент анализа и интерпретации технической информации. Однако здесь принципиально важен вопрос ответственности. ИИ не должен самостоятельно принимать критические решения. Оптимальная модель – человек, «усиленный» возможностями ИИ.

Третье направление – автоматизация технической поддержки. Значительная часть обращений пользователей является типовой: восстановление доступа, получение информации, настройка программного обеспечения, регистрация и маршрутизация заявок (документов). В таких случаях ИИ может выполнять первичную обработку обращений, находить информацию в базе знаний и запускать заранее определенные процедуры. Это позволяет направить специалистов на решение действительно сложных задач. При этом чем выше последствия возможной ошибки, тем больше должна быть роль человека в принятии решения. Речь идет не о замене сотрудников ИИ, а о перераспределении их времени от рутинных операций к задачам, требующим профессионального опыта и ответственности.

Однако развитие интеллектуальных систем создает и новые вызовы. ИИ сам становится объектом защиты. Среди актуальных угроз – попытки воздействовать на поведение модели, утечка конфиденциальной информации, использование недостоверных данных, уязвимости компонентов системы и предоставление модели избыточных полномочий. Эти риски уже систематизированы в рекомендациях OWASP и MITRE ATLAS (безопасность должна закладываться не после внедрения ИИ, а на этапе проектирования системы). Для образовательных организаций особенно важен вопрос защиты персональных данных. При этом нельзя считать обезличивание данных гарантией полного соответствия законодательству. Федеральный закон №152-ФЗ предусматривает комплекс правовых, организационных и технических мер защиты персональных данных, а обезличивание является только одним из инструментов. Поэтому при работе с чувствительной информацией необходимо рассматривать различные варианты архитектуры, в том числе локальное или закрытое развертывание моделей. Такие решения уже существуют, что показывает переход ИИ из области экспериментальных технологий в область практической инфраструктуры. Аналогичная ситуация складывается с системами информационной безопасности. Уже существуют SIEM-решения с интеллектуальной аналитикой, средства анализа поведения пользователей, локальные языковые модели и платформы для их развертывания. Это позволяет сделать важный вывод: университету не обязательно создавать новую цифровую систему с нуля. Более реалистичным является развитие существующей инфраструктуры за счет интеллектуальных функций. При этом ИИ следует рассматривать как часть более широкой архитектуры безопасности. Например, принцип

«нулевого доверия» предполагает, что пользователю или устройству нельзя автоматически доверять только потому, что они находятся внутри университетской сети. Доступ должен определяться идентичностью пользователя, состоянием устройства и необходимыми правами.

Практическое внедрение ИИ целесообразно начинать не с выбора самой современной модели, а с анализа конкретных проблем университета. Необходимо определить, сколько времени специалисты тратят на обработку инцидентов, какая доля обращений в службу поддержки является типовой, сколько ложных срабатываний формирует система мониторинга и какие задачи остаются без своевременной реакции. На основании этого выбираются несколько пилотных сценариев с измеримыми результатами. Если технология действительно сокращает время обработки, снижает нагрузку на специалистов или повышает качество обнаружения инцидентов, ее можно масштабировать.

Таким образом, ИИ уже не является исключительно перспективной технологией – необходимые инструменты существуют и могут применяться в университетской инфраструктуре уже сегодня. Но это совсем не означает необходимости тотального внедрения ИИ. Главный вопрос должен звучать иначе: какие задачи ИИ способен решать эффективнее существующих инструментов и при этом безопасно? Именно такой подход соответствует современному пониманию технологических инноваций, когда инновацией является не само наличие новой технологии, а получение от нее реального результата.

Список литературы

1. Тарануха С. Н. Риски и возможности использования генеративного искусственного интеллекта в образовательном процессе / С. Н. Тарануха // Проблемы современного образования. – 2025. – №5. – С. 219-227. URL: https://cyberleninka.ru/article/n/riski-i-vozmozhnosti-ispolzovaniya-generativnogo-iskusstvennogo-intellekta-v-obrazovatelnom-protsesse.
2. Zhang, Y. A Systematic Review on Technologies and Applications in Smart Campus: A Human-Centered Case Study / Y. Zhang, C. Yip, E. Lu [et al.] // CityUHK Scholars. – 2022. – Vol. 10. – P. 16135-16149. – DOI: 10.1109/ACCESS.2022.3148735
3. Lopez-Goyez, J. P. Smart Campus in Higher Education: A Systematic Review of Intelligent Technologies, Information Systems, and Sustainable Digital Ecosystems / J. P. López-Goyez, A. González-Briones, J. Guaytarilla // Applied Sciences. – 2026. – Vol. 16, № 14. – Art. 7277. – Текст: электронный. – DOI: https://doi.org/10.3390/app16147277
4. National Institute of Standards and Technology: Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile / C. Autio, R. Schwartz, J. Dunietz [et al.]. – Gaithersburg: National Institute of Standards and Technology, 2024. – (NIST AI 600-1)

УДК 004.8:004.912

СИСТЕМЫ АВТОМАТИЧЕСКОЙ ПРОВЕРКИ ФАКТИЧЕСКОЙ ДОСТОВЕРНОСТИ ТЕКСТОВ, ГЕНЕРИРУЕМЫХ ИСКУССТВЕННЫМ ИНТЕЛЛЕКТОМ

Дяченко А.С., ORCID 0009-0009-5362-4726, ***Тимофеев Б.И., Комендаков Д.И.***
ФГБОУ ВО «Мелитопольский государственный университет», г. Мелитополь, РФ
anna.dyachenko597@mail.ru, GooseShelter@yandex.ru, danil-komendakov@rambler.ru

Введение. Активное распространение генеративного искусственного интеллекта сопровождается ростом объема автоматически создаваемых текстов, что актуализирует проблему их фактической достоверности. Даже грамматически корректный и убедительно сформулированный ответ искусственного интеллекта (ИИ) может содержать ошибочные сведения, вымышленные факты или ссылки на несуществующие источники [1]. В связи с этим особую значимость приобретают системы автоматической проверки, способные выявлять потенциально недостоверные утверждения и обеспечивать их последующую верификацию [2; 4].

Цель исследования заключается в разработке и апробации методики автоматической проверки фактической достоверности текстов, генерируемых искусственным интеллектом, на основе поэтапного выявления утверждений, сопоставления их с внешними источниками и определения степени подтвержденности информации.

Основная часть. Принципиальное отличие проверки текста, созданного генеративной моделью, от традиционной проверки информации связано с вероятностью появления «галлюцинаций» – правдоподобных, но фактически неверных сведений. Поэтому проверке должны подвергаться прежде всего отдельные фактические утверждения о лицах, событиях, датах, количественных показателях, научных результатах и причинно-следственных связях [3; 4].

Предлагаемая методика включает четыре этапа: семантическое выделение проверяемых утверждений; поиск независимых источников; сопоставление утверждений с найденными сведениями; классификация результатов как «подтверждено», «опровергнуто», «частично подтверждено» или «требует дополнительной проверки». При выборе источников приоритет следует отдавать научным публикациям, официальным базам данных, государственным ресурсам и материалам организаций, непосредственно связанным с проверяемым событием [3].

Для повышения надежности оценки целесообразно учитывать не только соответствие утверждения сведениям источника, но и авторитетность и независимость источников. Одного интернет-ресурса недостаточно для автоматического признания информации достоверной; наличие

нескольких независимых подтверждений повышает обоснованность результата, а противоречивые сведения требуют экспертного анализа.

Практическая апробация методики может проводиться на корпусе из 100 утверждений, сформированных генеративной моделью по тематике конкретной учебной дисциплины. В качестве модельного примера 60 утверждений относятся к достоверным, 25 содержат фактические ошибки и 15 являются частично достоверными. При автоматической проверке 87 утверждений классифицированы корректно, 8 отнесены к неверной категории, а 5 признаны требующими дополнительной проверки. Таким образом, модельная точность классификации составляет 87 %. Указанные показатели являются примером оформления результатов и при публикации должны быть заменены фактическими данными собственного исследования.



Рис. Результаты точности классификации модельного примера

Практическая значимость предлагаемого подхода заключается в возможности его применения в образовательных, научных и информационных системах. В образовательной среде он может использоваться для предварительной проверки рефератов, эссе и ответов, подготовленных с помощью ИИ, а в научной сфере для дополнительной проверки фактологических и библиографических сведений. Возможность применения ИИ для автоматизированного анализа и проверки информационных материалов рассматривается в исследованиях, посвященных автоматической верификации информации [2; 4].

Важным условием эффективности системы является объяснимость результатов. Пользователь должен получать не только итоговый статус утверждения, но и информацию об источнике подтверждения или опровержения, выявленном противоречии и степени уверенности алгоритма. Это позволяет оценивать доказательную базу и сохранять экспертный контроль над процессом проверки.

Перспективным направлением является создание многоуровневых систем, объединяющих генеративные модели, поисковые технологии, базы знаний и алгоритмы семантического сопоставления. Их эффективность определяется сочетанием автоматического выявления потенциальных ошибок, прозрачного представления доказательств и возможности экспертной проверки спорных случаев.

Заключение. Системы автоматической проверки фактической достоверности способны существенно повысить надежность текстов, генерируемых ИИ, однако их оптимальное применение предполагает сочетание автоматического анализа с экспертной оценкой.

Список литературы

1. Дяченко А. С. Цифровая зависимость студентов как педагогическая проблема: диагностика и профилактика / А. С. Дяченко // Психолого-педагогическое образование: традиции и перспективы: материалы IX Всероссийской онлайн-конференции психологов образования Сибири с международным участием, Иркутск, 22–23 июня 2026 года. – Иркутск: Иркутский государственный университет, 2026. – С. 348–350. – EDN IKADRX.
2. Ильиных Н. А. Использование информационных платформ и искусственного интеллекта в противодействии фейковым новостям как мера предупреждения киберэкстремизма / Н. А. Ильиных // Научный вестник Омской академии МВД России. – 2025. – Т. 31, № 1 (96). – С. 37–43.
3. Чаканова С. Ж. YANDEX GPT как инструмент искусственного интеллекта: возможности и ограничения в обработке текста / С. Ж. Чаканова, Ю. Н. Рахматжоновна // НИР/S&R. – 2026. – № 1 (25). – С. 47-55.
4. Чибидин А. С. Методология применения алгоритм-ассистента в научных исследованиях: верификация данных и оптимизация исследовательских процессов / А. С. Чибидин // Инновационная наука. – 2025. – № 6-2. – С. 76-81.

УДК 004.415.2:616.89

МЯГКОЕ ПЛАНИРОВАНИЕ КАК ПОДХОД К ПРОЕКТИРОВАНИЮ ПЕРСОНАЛЬНЫХ ИНСТРУМЕНТОВ ДЛЯ СТУДЕНТОВ С ТРЕВОЖНО-ДЕПРЕССИВНЫМ ПРОФИЛЕМ: ОПЫТ ДИЗАЙН-ОРИЕНТИРОВАННОГО ИССЛЕДОВАНИЯ

Евдокимова А.Н., ORCID 0009-0000-2217-7710,
Погорелов А.А., ORCID 0009-0008-6921-0600
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
AnsiaEvmo@ya.ru, a.pogorelov.dstu@mail.ru

Введение. Цифровые инструменты персонального планирования стали неотъемлемой частью учебной и профессиональной деятельности.

Большинство современных планировщиков ориентировано на повышение продуктивности за счёт использования серий выполненных задач (streaks), достижений, напоминаний и визуального выделения просрочек. Несмотря на эффективность подобных решений, для студентов с повышенной тревожностью или депрессивными проявлениями они могут становиться дополнительным источником психологического давления [1, 2].

В исследованиях по взаимодействию человека и компьютера (HCI) данная проблема рассматривается в контексте персональной информатики, цифровых технологий поддержки психического благополучия и проектирования интерфейсов для пользователей с различными психологическими особенностями [3, 4]. Одним из перспективных подходов является **Research through Design (RtD),** позволяющий получать исследовательские результаты в процессе проектирования [5].

Цель исследования – разработка принципов проектирования персонального планировщика для студентов с тревожно-депрессивным профилем и создание программного прототипа, реализующего концепцию **мягкого планирования,** при которой механики оценки успешности заменяются решениями, снижающими эмоциональное напряжение и поддерживающими комфортное возвращение пользователя к планированию.

Исследовательский вопрос заключается в том, могут ли принципы мягкого планирования снизить субъективную психологическую нагрузку без потери функциональности цифрового планировщика.

Научная новизна заключается в формулировке и практической реализации принципов мягкого планирования в виде работающего программного прототипа.

Основная часть. Исследование выполнено в логике **Research through Design** с элементами автоэтнографии. Личный опыт использовался как источник проектных гипотез, а выводы формировались с учётом анализа научной литературы и внешней обратной связи [5, 6].

Основанием для проектирования послужил анализ типичных механизмов, используемых в современных цифровых планировщиках. Многие из них ориентированы на поддержание постоянной активности пользователя посредством уведомлений, систем достижений, серий выполненных задач и визуального выделения просрочек. Подобные механики способны повышать мотивацию, однако для пользователей с повышенной тревожностью могут становиться источником дополнительного эмоционального напряжения и способствовать отказу от дальнейшего использования приложения после длительного перерыва. В связи с этим при разработке программного прототипа основное внимание было уделено минимизации оценочных элементов интерфейса и созданию условий для комфортного возобновления процесса планирования независимо от предыдущей активности пользователя.

Проектирование осуществлялось итерационно: каждое изменение интерфейса оценивалось с точки зрения удобства восприятия, когнитивной

нагрузки и соответствия принципам мягкого планирования. Такой подход позволил последовательно отказаться от решений, способных усиливать чувство вины или неуспешности, и сформировать набор проектных принципов, ориентированных на психологически комфортное взаимодействие пользователя с системой.

Разработан программный прототип персонального планировщика на PyQt6. В отличие от традиционных систем он не использует серии выполненных задач, достижения и агрессивную индикацию просрочек. Вместо этого применяется **мягкая приоритизация**, при которой задачи распределяются по трём уровням важности без оценочных сообщений.

Реализованы декомпозиция задач, нейтральное отображение прогресса, трекер настроения, локальное хранение данных и опциональная синхронизация.

Особое внимание уделено сценарию возвращения пользователя после длительного перерыва. Интерфейс не создаёт ощущения накопленного долга и позволяет постепенно возобновить планирование. По результатам проектирования сформулированы три принципа мягкого планирования: **«не наказывать за отсутствие», «предсказуемость вместо вовлечённости»** и **«прозрачность данных».**

Заключение. В работе предложен подход к проектированию персональных цифровых планировщиков, основанный на принципах мягкого планирования и реализованный в виде программного прототипа. Полученные результаты показывают, что отказ от оценочных механик, использование мягкой приоритизации и ориентация на постепенное возвращение пользователя к планированию позволяют сформировать более психологически комфортную модель взаимодействия с системой.

Практическая значимость состоит в возможности применения предложенных принципов при разработке цифровых планировщиков. Дальнейшие исследования будут направлены на проведение пользовательского тестирования разработанного приложения, количественную оценку субъективной нагрузки и сравнительный анализ предложенного подхода с традиционными системами планирования.

Список литературы

1. Bardram, J. E. Designing mobile health technology for bipolar disorder / J. E. Bardram, M. Frost, K. Szántó [et al.] // Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. – New York: ACM, 2013. – P. 1377–1386. – DOI 10.1145/2470654.2481364.
2. Doherty G. Design and evaluation guidelines for mental health technologies / G. Doherty, D. Coyle, M. Matthews // Interacting with Computers. – 2010. – Vol. 22, no. 4. – P. 243–252. – DOI 10.1016/j.intcom.2010.02.006.
3. Epstein, D. A. A lived informatics model of personal informatics / D. A. Epstein, A. Ping, J. Fogarty, S. A. Munson // Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing. – New York : ACM, 2015. – P. 123–134. – DOI 10.1145/2750858.2804250.

4. Sanches, P. HCI and Affective Health / P. Sanches, A. Janson, P. Karpashevich [et al.] // Proceedings of the CHI Conference on Human Factors in Computing Systems (CHI 2019). – New York: ACM, 2019. – 17 p.
5. Zimmerman, J. Research Through Design in HCI / J. Zimmerman, J. Forlizzi // Ways of Knowing in HCI. – New York: Springer, 2014. – P. 167–189.
6. Ellis, C. Autoethnography: An Overview / C. Ellis, T. E. Adams, A. P. Bochner // Forum: Qualitative Social Research. – 2011. – Vol. 12, no. 1. – P. 1–28.

УДК 004.912

ОБОСНОВАНИЕ ВЫБОРА МЕТОДОВ АСПЕКТНОГО АНАЛИЗА ТОНАЛЬНОСТИ РУССКОЯЗЫЧНЫХ ОТЗЫВОВ О ВИДЕОИГРАХ

Ермоленко Т.В., канд. техн. наук, доц., ORCID 0000-0001-5701-1956,
Ефимова В.А., ORCID 0009-0000-8873-5711
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
naturewild71@gmail.com, vlada.efimovaa@yandex.ru

Введение. Объём пользовательских отзывов о видеоиграх делает их ручную обработку трудоёмкой. Отзыв об игре, как правило, содержит оценки отдельных аспектов – сюжета, персонажей, боевой системы, графики, монетизации, технического состояния, – которые могут иметь разную тональность. Поэтому для выявления факторов удовлетворённости игроков недостаточно определить общую тональность отзыва: требуется аспектный анализ тональности (aspect-based sentiment analysis, ABSA), при котором тональность определяется для каждого упомянутого аспекта.

Актуальность работы обусловлена тем, что для русского языка аспектные корпуса существуют лишь для отдельных предметных областей, например отзывов о ресторанах и автомобилях [1], а размеченных данных по видеоиграм нет. Выбор методов при этом неочевиден из-за быстрого развития языковых моделей.

Целью работы является сравнение методов определения тональности русскоязычных текстов и обоснование выбора методов для системы, оценивающей тональность отзывов о видеоигре Honkai: Star Rail по отдельным аспектам.

Основная часть. *Критерии выбора методов.* Особенности отзывов о Honkai: Star Rail, публикуемых в Google Play и на игровых порталах StopGame, Playground.ru и VGTimes, определяют пять критериев выбора:

К1 – качество классификации русскоязычных текстов, оцениваемое макро-F1 на открытых корпусах;

К2 – возможность определять тональность отдельных аспектов, поскольку один отзыв содержит разнонаправленные оценки сюжета, персонажей, монетизации и других характеристик игры;

К3 – учёт контекста: иронии и сарказма [2], а также игровой лексики («крутки», «гарант», «имба»), отсутствующей в общих словарях;

К4 – объём требуемой ручной разметки, поскольку размеченных отзывов о видеоиграх нет;

К5 – вычислительные затраты при обработке больших массивов отзывов.

Классы методов. Обзор методов определения тональности русскоязычных текстов приведён в [3]. Словарные методы используют лексиконы оценочных слов, например RuSentiLex [4]: они не требуют разметки, но не учитывают контекст и игровую лексику. Классическое машинное обучение (TF-IDF с логистической регрессией или SVM) и нейросети на векторах слов требуют размеченной выборки и обычно определяют тональность отзыва целиком. Модели семейства BERT, в том числе обученная на русскоязычных текстах RuBERT [5], учитывают контекст и после дообучения показывают лучшие результаты на корпусах RuSentiment [6] и RuReviews [7] [8]. Большие языковые модели (LLM) классифицируют тональность без дообучения: по данным [9], в простой классификации они близки к дообученным моделям, но уступают им при оценке отдельных аспектов, зато значительно превосходят малые модели при обучении на нескольких примерах. Сравнение классов методов приведено в табл.

Таблица

Сравнение классов методов по критериям К1–К5 для аспектной оценки тональности отзывов о видеоиграх

Класс методов	**К1: макро-F1, %**	**К2: аспекты**	**К3: контекст, ирония**	**К4: разметка**	**К5: затраты**
Словарные [4]	–	через словарь аспектов	не учитывают	не нужна	низкие
Классическое МО (TF-IDF + LR, SVM)	–	нет	слабо	нужна	низкие
CNN на векторах слов [7]	RuReviews: 75,45	нет	частично	нужна	средние
RuBERT с дообучением [5]	RuReviews: 77,44; RuSentiment: 72,03	да, при постановке ABSA	учитывают	нужна	средние
LLM без дообучения [9]	≈97 % от дообученной модели*	да, хуже дообученных	учитывают	не нужна или несколько примеров	высокие

Примечание. Значения макро-F1 – по [8]: RuReviews – 3 класса, RuSentiment – 5 классов; «–» – сопоставимые результаты не приводятся.

*Простая классификация тональности на англоязычных корпусах [9].

Обоснование выбора. Из табл. 1 следует, что ни один класс методов не удовлетворяет всем критериям. Дообученная RuBERT лучшая по К1 и отвечает К2 и К3, но не К4: размеченных отзывов о видеоиграх нет. LLM отвечают К3 и К4, но уступают по К2 и К5. Словарные и классические

методы экономичны (К5), но не отвечают К2 и К3. Поэтому обоснована комбинированная схема, в которой LLM снимает ограничение по К4, а RuBERT обеспечивает К1–К3 и приемлемые затраты при обработке основного массива отзывов:

1) выделение аспектов по словарю игровых аспектов, составленному на выборке отзывов и расширяемому с помощью LLM;

2) предварительная разметка тональности аспектов с помощью LLM на нескольких примерах с выборочной ручной проверкой – сочетание автоматической и ручной обработки повышает достоверность оценок [2];

3) дообучение классификатора на основе RuBERT на полученном корпусе как основного компонента системы;

4) сравнение с базовыми решениями – словарным методом, TF-IDF с логистической регрессией и LLM без дообучения – по макро-F1 для каждого аспекта.

Тональности по аспектам затем агрегируются по всем отзывам, что позволяет выявить аспекты игры, сильнее всего связанные с удовлетворённостью игроков.

Заключение. Сравнение методов показало, что для аспектной оценки тональности русскоязычных отзывов о видеоиграх главным ограничением является отсутствие размеченных данных, а не качество моделей. Обоснована комбинированная схема: LLM используется для предварительной разметки, а основным классификатором служит дообученная RuBERT, показывающая лучшее качество на русскоязычных корпусах при меньших затратах на обработку. Дальнейшая работа – сбор и разметка корпуса отзывов о Honkai: Star Rail и экспериментальная проверка предложенной схемы.

Список литературы

1. Loukachevitch N. V. SentiRuEval: testing object-oriented sentiment analysis systems in Russian / N. V. Loukachevitch, P. D. Blinov, E. V. Kotelnikov [et al.] // Компьютерная лингвистика и интеллектуальные технологии: по материалам ежегодной междунар. конф. «Диалог». – 2015. – Вып. 14 (21), т. 2. – С. 3-15.
2. Гималетдинова Г. К. Сентимент-анализ читательского комментария: автоматизированная vs ручная обработка текста / Г. К. Гималетдинова, Э. Х. Довтаева // Учёные записки Казанского университета. Серия: Гуманитарные науки. – 2021. – Т. 163, кн. 1. – С. 65–80. – DOI: 10.26907/2541-7738.2021.1.65-80.
3. Smetanin S. The applications of sentiment analysis for Russian language texts: current challenges and future perspectives / S. Smetanin // IEEE Access. – 2020. – Vol. 8. – P. 110693–110719. – DOI: 10.1109/ACCESS.2020.3002215.
4. Loukachevitch N. Creating a general Russian sentiment lexicon / N. Loukachevitch, A. Levchik // Proc. of the 10th Int. Conf. on Language Resources and Evaluation (LREC 2016). – 2016. – P. 1171–1176.
5. Kuratov Y. Adaptation of deep bidirectional multilingual transformers for Russian language / Y. Kuratov, M. Arkhipov // Компьютерная лингвистика и интеллектуальные технологии: по материалам ежегодной междунар. конф. «Диалог». – 2019. – Вып. 18. – С. 333–339.

6. Rogers A. RuSentiment: an enriched sentiment analysis dataset for social media in Russian / A. Rogers, A. Romanov, A. Rumshisky [et al.] // Proc. of the 27th Int. Conf. on Computational Linguistics (COLING 2018). – 2018. – P. 755–763.
7. Smetanin S. Sentiment analysis of product reviews in the Russian language using convolutional neural networks / S. Smetanin, M. Komarov // 2019 IEEE 21st Conf. on Business Informatics (CBI). – 2019. – Vol. 1. – P. 482–486.
8. Smetanin S. Deep transfer learning baselines for sentiment analysis in Russian / S. Smetanin, M. Komarov // Information Processing & Management. – 2021. – Vol. 58. – Art. 102484. – DOI: 10.1016/j.ipm.2020.102484.
9. Zhang W. Sentiment analysis in the era of large language models: a reality check / W. Zhang, Y. Deng, B. Liu [et al.] // Findings of the Association for Computational Linguistics: NAACL 2024. – 2024.

УДК 004.932

МЕТОДЫ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ АВТОМАТИЗИРОВАННОГО ОБНАРУЖЕНИЯ ДЕФЕКТОВ ДОРОЖНОГО ПОКРЫТИЯ

Ермоленко Т.В., канд. техн. наук, доц., ORCID 0000-0001-5701-1956,
Мартынов В.В. ORCID 0009-0001-6904-9131
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
naturewild71@gmail.com, vladmartinov1704@mail.ru

Введение. Состояние дорожного покрытия напрямую влияет на безопасность движения и срок службы дорог. Традиционный мониторинг основан на визуальном осмотре: он трудоёмок, зависит от субъективной оценки инспектора и не обеспечивает непрерывного контроля протяжённой дорожной сети.

Актуальность работы определяется необходимостью перехода от периодических ручных обследований к автоматизированному мониторингу на недорогом оборудовании, в режиме, близком к реальному времени, с привязкой дефектов к координатам.

Целью работы является сравнительный анализ методов глубокого обучения и наборов данных для обнаружения, сегментации и оценки серьёзности дефектов дорожного покрытия, а также обоснование выбора компонентов архитектуры разрабатываемой системы мониторинга по видеосъёмке со смартфона.

Основная часть. *Обнаружение дефектов.* Одноэтапные детекторы семейства YOLO обрабатывают изображение за один проход и подходят для работы в реальном времени [1, 2]. В работе [2] детектор YOLOv8 дополнен сопровождением дефектов между кадрами видео с помощью фильтра Калмана и венгерского алгоритма. Возможность обнаружения

повреждений непосредственно на смартфоне, закреплённом в автомобиле, показана в [3] на наборе из 9 053 изображений с восемью типами повреждений.

Сегментация. Пиксельная маска, в отличие от ограничивающей рамки, позволяет измерить площадь, ширину и ориентацию дефекта. Для сегментации трещин применяются U-Net и полносвёрточные сети [4, 5]; в [4] нехватку размеченных данных компенсируют синтетическими изображениями, полученными генеративно-состязательной сетью, а в [1] выбоины сегментируются моделью YOLOv8-seg.

Наборы данных. Крупнейший открытый набор RDD2022 содержит 47 420 изображений из шести стран с разметкой рамками четырёх типов повреждений; лучшая модель соревнования CRDDC’2022 достигла на нём F1-меры 76,9 % [6]. Масок и сведений о серьёзности в нём нет. Набор Attain включает 2 293 снимка со смартфона с 19 761 дефектом десяти типов [7], набор CRACK500 – 500 снимков трещин с попиксельной разметкой [8].

Оценка серьёзности. Предельно допустимые размеры повреждений покрытия установлены ГОСТ Р 50597-2017 [9], методика оценки состояния покрытия при диагностике дорог – ОДН 218.0.006-2002 [10]. В работе [11] система из моделей SqueezeNet, U-Net и MobileNet-SSD определяет вид трещины (пять видов) и её серьёзность с точностью 91,2 %. В таблице приведено сравнение рассмотренных работ по задачам, моделям и реализованным функциям.

Таблица

Сравнение рассмотренных моделей

Задача	**Модели**	**Маска***	**Серьёз-ность**	**Видео, трекинг**	**Смарт-фон****	**GPS**
Сегментация выбоин [1]	YOLOv8-seg	+	–	–	–	–
Детекция и трекинг [2]	YOLOv8, фильтр Калмана, венгерский алгоритм	–	–	+	–	–
Детекция, 8 типов [3]	SSD (Inception, MobileNet)	–	–	–	+	+
Сегментация трещин и выбоин [4]	U-Net, синтетика (GAN)	+	–	–	–	–
Сегментация трещин [5]	Полносвёрточная сеть	+	–	–	–	–
Детекция, 4 типа [6]	Ансамбль YOLO и Faster R-CNN	–	–	–	–	–
Вид и серьёзность трещин [11]	SqueezeNet, U-Net, MobileNet-SSD	+	+	–	–	–

*Маска означает, что метод строит попиксельную маску дефекта, то есть выполняет сегментацию. На выходе получается точный контур трещины или выбоины, а не только прямоугольная рамка вокруг неё.
**Смартфон – обработка изображений непосредственно на смартфоне, «+» – функция реализована, «–» – не реализована.

Как видно из таблицы, каждая работа охватывает лишь часть функций, необходимых для практического мониторинга. На основе проведённого анализа обоснован следующий выбор компонентов архитектуры:

1) детектор – YOLO: обработка за один проход обеспечивает работу в реальном времени, в том числе на мобильных устройствах [1–3]; ансамбли с двухэтапным детектором Faster R-CNN точнее [6], но слишком ресурсоёмки для смартфона;

2) сегментация – U-Net, хорошо зарекомендовавшая себя на трещинах и выбоинах [4, 5] и в связке с детектором при оценке серьёзности [11]; способ совместной работы с детектором (сегментация всего кадра или только найденных областей) предстоит выбрать экспериментально;

3) сопровождение – фильтр Калмана и венгерский алгоритм [2], позволяющие объединять повторные наблюдения одного дефекта в видеопотоке перед привязкой к GPS-координатам;

4) обучающие данные – RDD2022 [6] для детектора, CRACK500 [8] для сегментационной модели, Attain [7] и собственные видеозаписи со смартфона с GPS-треком для адаптации к условиям съёмки;

5) оценка серьёзности – по геометрическим параметрам маски (площадь, ширина, длина) с пороговыми значениями на основе [9, 10].

Размещение вычислений (на смартфоне [3] или на сервере) предполагается выбрать по результатам экспериментального сравнения.

Заключение. Сравнительный анализ (табл. 1) показал, что функции, необходимые для мониторинга, реализованы в рассмотренных работах по отдельности. На этой основе обоснован выбор компонентов архитектуры будущей системы: YOLO, U-Net, сопровождение на основе фильтра Калмана и оценка серьёзности по геометрии маски. Дальнейшая работа направлена на реализацию этой архитектуры и её экспериментальную проверку.

Список литературы

1. Канаева И. А. Сегментация выбоин с помощью сверточной нейронной сети YOLOv8 / И. А. Канаева, В. Г. Спицын // Молодежь и современные информационные технологии: сборник трудов XXI Международной научно-практической конференции студентов, аспирантов и молодых ученых (Томск, 15–18 апреля 2024 г.). – Томск: Изд-во ТПУ, 2024. – С. 262–266.
2. Антонов М. О. Распознавание и отслеживание дефектов дорожного полотна в реальном времени на основе комплексного использования стандартных вычислительных процедур и глубоких нейронных сетей / М. О. Антонов, И. О. Темкин // Программные продукты и системы. – 2024. – Т. 37, № 3. – С. 421–430.
3. Maeda H. Road damage detection and classification using deep neural networks with smartphone images / H. Maeda, Y. Sekimoto, T. Seto [et al.] // Computer-Aided Civil and Infrastructure Engineering. – 2018. – Vol. 33. – P. 1127–1141. – DOI: 10.1111/mice.12387.
4. Канаева И. А. Сегментация дефектов дорожного покрытия на основе формирования синтетических выборок с помощью глубоких генеративно-состязательных свёрточных сетей / И. А. Канаева, Ю. А. Иванова, В. Г. Спицын // Компьютерная оптика. – 2021. – Т. 45, № 6. – С. 907–916. – DOI: 10.18287/2412-6179-CO-844.

5. Соболь Б. В. Модель глубокой сверточной нейронной сети в задаче сегментации трещин на изображениях асфальта / Б. В. Соболь, А. Н. Соловьев, П. В. Васильев и др. // Вестник Донского государственного технического университета. – 2019. – Т. 19, № 1. – С. 63–73. – DOI: 10.23947/1992-5980-2019-19-1-63-73.
6. Arya D. RDD2022: A multi-national image dataset for automatic road damage detection / D. Arya, H. Maeda, S. K. Ghosh [et al.] // Geoscience Data Journal. – 2024. – Vol. 11, № 4. – P. 846–862. – DOI: 10.1002/gdj3.260.
7. Rezaeimanesh, M. Attain / M. Rezaeimanesh, A. Golroo, M. S. Fahmani [et al.] // Mendeley Data. – 2025. – V. 1. – DOI: 10.17632/nykrzdm74f.1 (дата обращения: 12.09.2026).
8. Yang F. Feature pyramid and hierarchical boosting network for pavement crack detection / F. Yang, L. Zhang, S. Yu [et al.] // IEEE Transactions on Intelligent Transportation Systems. – 2020. – Vol. 21, № 4. – P. 1525–1535.
9. ГОСТ Р 50597-2017. Дороги автомобильные и улицы. Требования к эксплуатационному состоянию, допустимому по условиям обеспечения безопасности дорожного движения. Методы контроля. – М.: Стандартинформ, 2017.
10. ОДН 218.0.006-2002. Правила диагностики и оценки состояния автомобильных дорог. Основные положения. – М.: Росавтодор, 2002.
11. Ha J. Assessing severity of road cracks using deep learning-based segmentation and detection / J. Ha, D. Kim, M. Kim // The Journal of Supercomputing. – 2022. – Vol. 78, № 16. – P. 17721–17735. – DOI: 10.1007/s11227-022-04560-x.

УДК 004.048

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ В УСЛОВИЯХ ОГРАНИЧЕННЫХ ДАННЫХ

Ефименко К.Н., канд. техн. наук, доц., ORCID 0000-0002-9036-2093,
Савенко М.О., ORCID 0009-0002-5735-4048
ФГБОУ ВО «Донецкий национальный технический университет», г. Донецк, РФ
kn_efimenko@mail.ru, nomad_200018@mail.ru

Введение. Прогнозирование временных рядов относится к числу фундаментальных задач прикладной информатики, теории управления и системного анализа. В условиях цифровизации экономики и промышленности точность краткосрочных прогнозов напрямую влияет на качество принимаемых решений: от планирования нагрузки энергосистем до управления цепями поставок и финансовыми потоками. Особую значимость эта задача приобретает в ситуациях, когда объем доступных ретроспективных данных ограничен – например, при прогнозировании на начальных этапах эксплуатации объекта, в условиях редких измерений или при работе с данными новых территорий и отраслей [1].

Основная часть. В качестве объекта исследования сгенерирован временной ряд суточного потребления электроэнергии за 90 дней. Ряд

включает линейный тренд, недельную сезонность (период 7 дней) и аддитивный гауссовский шум [2]. Синтетические данные выбраны сознательно: это позволяет изолированно оценить устойчивость алгоритмов машинного обучения при малой выборке, исключив влияние аномалий и пропусков, характерных для реальных измерений.

Признаковое пространство формировалось на основе лагов (1, 2, 3 и 7 дней) и дня недели. Разбиение выборки проводилось по схеме «скользящего окна»: 70 % данных – обучающая выборка, 30 % – тестовая (без перемешивания, что критично для временных рядов). Для прогнозирования использовались три модели: линейная регрессия, случайный лес (Random Forest) и градиентный бустинг (Gradient Boosting). Оценка качества осуществлялась с помощью метрик MAE и RMSE. Результаты экспериментов представлены в таблице.

Таблица

Сравнение точности моделей прогнозирования

Модель	**MAE**	**RMS**
Линейная регрессия	1.59	2.13
Случайный лес	2.06	2.51
Градиентный бустинг	1.85	2.30

Как видно из таблицы, наилучшие результаты показала линейная регрессия с лаговыми признаками (MAE = 1.59, RMSE = 2.13). Этот результат может показаться неожиданным на фоне распространённого мнения о безусловном превосходстве ансамблевых методов, однако он имеет строгое объяснение, связанное со структурой исследуемого ряда. Синтетические данные были сгенерированы как сумма линейного тренда (0.15 × день), строгой синусоидальной сезонности с периодом 7 дней и аддитивного гауссовского шума. Такая структура является «дружественной» именно для линейных моделей: признак лага седьмого дня напрямую кодирует недельную периодичность, а признак номера дня – линейный тренд. В результате линейная регрессия описывает ряд практически без остатка, а её ошибка определяется только шумовой компонентой [3].

Ансамблевые методы – случайный лес (MAE = 2.06, RMSE = 2.51) и градиентный бустинг (MAE = 1.85, RMSE = 2.30) – показали более высокую ошибку. Это объясняется их склонностью к переобучению на малой выборке (90 наблюдений, из которых 63 – обучающие). Обе рассматриваемые модели относятся к классу ансамблей над решающими деревьями. Дерево, в отличие от линейной функции, не описывает зависимость формулой – оно «нарезает» признаковое пространство на участки, и внутри каждого возвращает одно и то же значение. Поэтому линейный тренд дерево воспроизвести не может: вне обучающего интервала оно не продолжает наклонную прямую, а фиксирует последнюю достигнутую величину. Визуально это проявляется в том, что кривая прогноза на тестовом отрезке становится горизонтальной. Дополнительный вклад

вносит малый объём выборки: при 63 обучающих точках деревья начинают фиксировать не закономерность, а единичные шумовые всплески. Это классический пример смещения в сторону переобучения – модель хорошо описывает прошлое, но теряет способность к обобщению [4].

Случайный лес уступил градиентному бустингу, что согласуется с теорией: бустинг последовательно корректирует ошибки предыдущих деревьев и потому точнее аппроксимирует целевую функцию. Ни случайный лес, ни градиентный бустинг так и не обошли линейную регрессию. Причина – в структуре ряда. Линейный тренд и регулярная периодичность описываются небольшим числом параметров, поэтому усложнение модели не даёт новых знаний о данных, а лишь увеличивает число настраиваемых параметров, оцениваемых по малой выборке. Иными словами, ансамбли «платят» за свою гибкость точностью. Здесь уместно вспомнить принцип, известный в статистике и машинном обучении как бритва Оккама: если простая модель объясняет данные не хуже сложной, предпочтение следует отдать простой. Полученный результат служит практической иллюстрацией этого принципа применительно к задаче краткосрочного прогнозирования.

Отдельно отметим, что сравнение проводилось по метрикам MAE и RMSE, которые по-разному штрафуют ошибки: MAE усредняет абсолютные отклонения и устойчива к выбросам, тогда как RMSE возводит ошибки в квадрат и сильнее реагирует на крупные промахи. Обе метрики дали согласованный результат, что повышает надёжность вывода о превосходстве линейной регрессии в данном эксперименте.

На рисунке представлен график фактических и прогнозных значений для лучшей модели на тестовом участке.

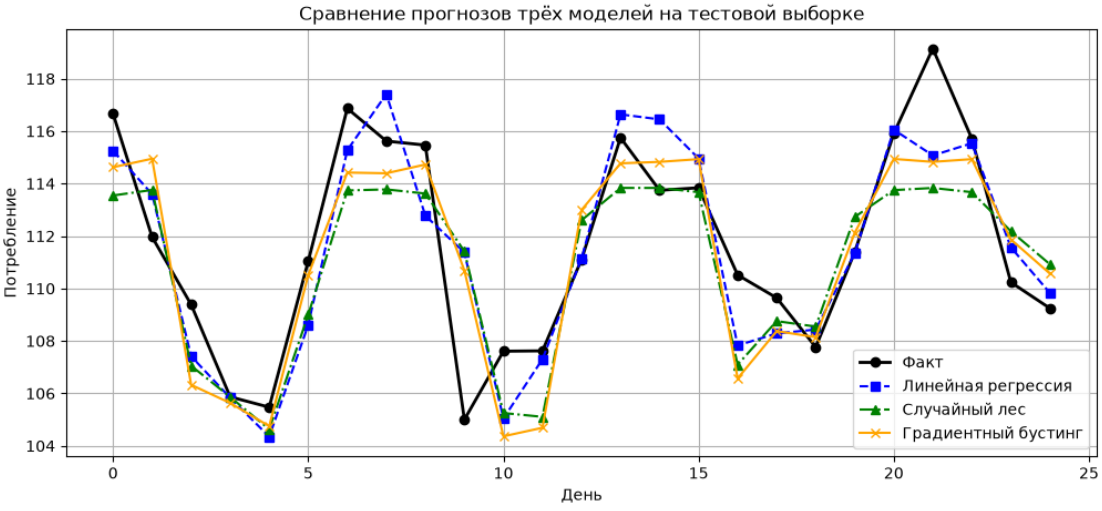


Рис. Фактические и прогнозные значения потребления электроэнергии (тестовая выборка)

Заключение. Установлено, что линейная регрессия с лаговыми признаками обеспечивает наименьшую ошибку прогноза (MAE = 1.59,

RMSE = 2.13) по сравнению со случайным лесом и градиентным бустингом. Это объясняется линейной природой тренда и строгой периодичностью сезонности в исследуемом ряде: ансамблевые методы не дают прироста точности при малом объёме выборки и явно выраженной линейной структуре данных.

Список литературы

1. Макаров В. Л. Прогнозирование временных рядов методами машинного обучения / В. Л. Макаров, А. Р. Бахтизин // Экономика и математические методы. – 2020. – Т. 56, № 2. – С. 5–18.
2. Чучуева И. А. Модель прогнозирования временных рядов по выборке максимального подобия: дис. ... канд. техн. наук. – М., 2012. – 150 с.
3. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow / A. Géron – O'Reilly Media, 2022. – 864 p.
4. Hyndman R. J. Forecasting: principles and practice / R. J. Hyndman, G. Athanasopoulos. – OTexts, 2021. – 442 p.

УДК 004.021:519.17

ИНТЕЛЛЕКТУАЛЬНЫЕ АЛГОРИТМЫ АДАПТИВНОЙ МАРШРУТИЗАЦИИ В СИСТЕМЕ УНИВЕРСИТЕТСКОЙ НАВИГАЦИИ

Зайцева В.А., ORCID 0009-0002-2438-9383,
Губенко Н.Е., канд. техн. наук, доц., ORCID 0009-0006-7385-2943
ФГБОУ ВО «Донецкий национальный технический университет», г. Донецк, РФ
vladislava.zay@mail.ru, negubenko@mail.ru

Введение. Современные университетские кампусы представляют собой сложные пространственные структуры, состоящие из множества корпусов, этажей и переходов. В условиях высокой плотности студенческих потоков, особенно в периоды начала учебных занятий и больших перемен, традиционные алгоритмы маршрутизации, основанные исключительно на физическом расстоянии, оказываются неэффективными. Кратчайший путь по расстоянию часто совпадает с наиболее загруженными коридорами и лестничными узлами, что приводит к образованию «пробок» и увеличению фактического времени в пути. Стандартные алгоритмы, такие как Дейкстра или классический A*, не учитывают контекстную информацию о том, что происходит в аудиториях в конкретный момент времени.

Целью данной статьи является разработка и математическое обоснование интеллектуального алгоритма адаптивной маршрутизации, который интегрирует пространственную навигацию и данные

динамического учебного расписания. Предлагаемый подход позволяет прогнозировать загруженность пространств и строить маршруты, оптимизированные не по расстоянию, а по фактическому времени прохождения, что напрямую способствует снижению когнитивной и физической нагрузки на участников учебного процесса**.**

Основная часть. В основе предлагаемой системы лежит представление университетского кампуса в виде взвешенного ориентированного графа $G = (V, E)$, где множество вершин Vвключает аудитории, узлы коридоров, лестничные клетки и входы, а множество рёбер E представляет собой коридоры, переходы и лестницы. В классической постановке задачи поиска кратчайшего пути вес ребра $w(e)$ является статическим и соответствует времени прохождения участка при идеальных условиях. В разработанной модели мы вводим понятие динамического веса $w(e, t)$, который является функцией от времени t:

$$w(e, t) = w_{base}(e) + \Delta w_{congestion}(e, t) \quad (1)$$

где $w_{base}(e)$ – базовое время прохождения ребра в свободном состоянии, а $\Delta w_{congestion}(e, t)$ – штрафной коэффициент, отражающий прогнозируемую загруженность ребра в момент времени t.

Значение Δw вычисляется на основе анализа учебного расписания. Для каждой вершины $v \in V$, являющейся аудиторией, в момент времени t определяется ожидаемое количество выходящих студентов $N_{out}(v, t)$ и входящих $N_{in}(v, t)$. Эти значения распределяются по инцидентным рёбрам коридоров с учетом коэффициента затухания расстояния и пропускной способности коридора $C(e)$. Таким образом, если в смежных с ребром e аудиториях заканчивается лекция с высокой наполняемостью, пропускная способность коридора снижается, а вес ребра нелинейно возрастает [1].

Для поиска оптимального маршрута в такой динамической среде был выбран алгоритм A* (A-star) в силу его эффективности при работе с эвристиками. Однако стандартный A* не учитывает изменяющиеся веса. В работе предлагается модификация алгоритма, в которой функция оценки стоимости $f(n)$ для узла n пересчитывается с учетом временных слотов:

$$f(n) = g(n, t) + h(n) \quad (2)$$

где $g(n, t)$ – фактическая стоимость пути от начальной вершины до узла n с использованием динамических весов $w(e, t)$, а $h(n)$ – эвристическая функция, оценивающая оставшееся расстояние до цели. В качестве эвристики используется евклидово расстояние, деленное на среднюю скорость пешехода в здании, что гарантирует допустимость эвристики и оптимальность найденного пути. Процесс адаптивной маршрутизации представлен на рисунке.

Интеграция данного алгоритма в модуль навигации веб-платформы позволяет визуализировать не просто линию маршрута, но и контекстную информацию о загруженности. Для количественной оценки влияния расписания на граф в таблице приведена матрица динамических весов для

ключевых участков первого этажа учебного корпуса. Данные показывают, как алгоритм пересчитывает стоимость прохождения конкретных физических сегментов в зависимости от времени суток.



Рис. Блок-схема процесса адаптивной маршрутизации

Таблица

Матрица динамических весов ребер графа для ключевых переходов первого этажа

Ребро графа	Базовый вес w_base(сек)	Вес в спокойное время (14:00)	Вес в час пик (08:50)	Коэффициент перегрузки
Коридор 1-го этажа	30	32	115	3.8
Лестничный узел А	45	48	140	3.1
Переход в корпус Б	120	125	130	1.1
Коридор 2-го этажа	25	26	45	1.8
Лестничный узел Б	50	52	65	1.3

Анализ таблицы подтверждает, что в час пик вес центрального коридора возрастает почти в 4 раза, в то время как вес запасного лестничного узла увеличивается незначительно. Именно на основе этих данных модифицированный алгоритм A* перенаправляет студентов через «запасной» путь, избегая образования пробок в главном холле [2].

Для проверки эффективности предложенного алгоритма было проведено имитационное моделирование на основе цифрового двойника одного из учебных корпусов (5 этажей, 4 лестничных узла, 85 аудиторий). В ходе эксперимента сравнивались два подхода: базовый алгоритм Дейкстры со статическими весами и предлагаемый модифицированный алгоритм A* с динамическими весами. Результаты показали, что в пиковые часы адаптивный алгоритм позволил сократить среднее фактическое время перемещения студентов на 18-22 % за счет перенаправления потоков через менее очевидные, но свободные переходы. При этом вычислительная сложность осталась в допустимых пределах: предварительный пересчет весов графа для одного временного слота занимает в среднем 12 мс на сервере (FastAPI, Python), а сам поиск маршрута – менее 40 мс, что полностью удовлетворяет нефункциональному требованию системы к быстродействию (<500 мс). Моделирование также подтвердило, что использование системы снижает максимальную плотность потока в главных холлах на 30 %, равномерно распределяя студентов по инфраструктуре кампуса.

Заключение. В статье обоснован подход к адаптивной маршрутизации в кампусе на основе интеграции графовой модели и расписания. Динамические веса рёбер позволяют алгоритму A* строить быстрые, а не просто короткие маршруты. Моделирование подтвердило

сокращение времени в пути на 22 % в часы пик. В перспективе планируется интеграция с Wi-Fi-телеметрией для развития концепции «Умный кампус».

Список литературы

1. Зайцева, В. А. Моделирование университетского кампуса в виде взвешенного графа: методология и практическая реализация / В. А. Зайцева, Н. Е. Губенко // Информатика, управляющие системы, математическое и компьютерное моделирование (ИУСМКМ-2026): Сборник материалов XVII Всероссийской научно-технической конференции с международным участием в рамках XII Международного научного форума Донецкой Народной Республики, Донецк, 22–23 апреля 2026 года. Том 1. – Донецк: Донецкий национальный технический университет, 2026. – С. 439-446. – EDN SSHCSD.
2. Беляков С. Л. Модель решения задачи маршрутизации в интеллектуальной геоинформационной системе / С. Л. Беляков, Я. А. Коломийцев, И. Н. Розенберг и др. // Известия ЮФУ. Технические науки. – 2011. – № 5(118). – С. 113-119. – EDN NTZLVP.

УДК 004.8:510.52

СРАВНИТЕЛЬНЫЙ АНАЛИЗ СЛОЖНОСТИ МОДЕЛЕЙ ИИ ПО ДАННЫМ OPEN LLM LEADERBOARD

***Звягинцева А.В.*[1,2]**, д-р техн. наук, доц., ORCID 0000-0003-2218-9230,
***Бражников А.Р.*[1]**, ORCID 0009-0005-4420-9206
[1]ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
[2]ФГБОУ ВО «Донецкий национальный технический университет», г. Донецк, РФ
zviagintsevaav@gmail.com, yanox123321@gmail.com

Введение. Число публично доступных языковых моделей выросло на порядки, а сопоставляют их по агрегированному баллу набора тестов: он фиксирует результат, но не описывает сложность модели как системы – при близком среднем балле модели различаются и по ресурсной размерности, и по структуре связей между способностями. Прекращение работы Open LLM Leaderboard [1] превращает его архивный срез в зафиксированный корпус, полученный по единому протоколу на шести тестах, что обеспечивает воспроизводимость расчётов.

Цель работы – сравнительная оценка сложности моделей ИИ по единому интегральному показателю на архивном срезе Open LLM Leaderboard.

Задачи: формирование очищенного корпуса; перенос показателя информационной сложности [2] с временных рядов на ансамбль моделей; расчёт и декомпозиция показателя по группам; проверка гипотезы о насыщении качества [3].

Основная часть. Законы масштабирования [3] трактуют сложность как ресурс и не различают модели сопоставимого бюджета. Системы

оценивания по тестам [1] дают профиль способностей, но свёртка в средний балл теряет структуру связей между шкалами. Энтропия Шеннона не учитывает эту структуру, а сложность Колмогорова невычислима [2]. Интегральной оценки для групп разнородных моделей ни один подход не даёт.

Методика. Единица анализа – группа моделей, объединённых по числу параметров X_1: статистическая компонента определяется через расхождение распределений, а отдельная модель задаёт единственную точку и распределения не образует. Модель описывается вектором $x = (x_1, \dots, x_6)$ значений по шести тестам лидерборда.

За опорное состояние P_0 принят кластер 3–8 млрд параметров – базовый сегмент самостоятельного развёртывания. По его выборочным моментам определяются вектор средних μ_0 и ковариационная матрица Σ_0. Статистическая компонента сложности группы g – дивергенция Йенсена-Шеннона, симметризованная дивергенция Кульбака-Лейблера относительно смеси распределений.

Замкнутой формы для арифметической JS-дивергенции гауссовых распределений не существует: их смесь не нормальна. Для одного экспоненциального семейства замкнутое выражение даёт геометрическая JS-дивергенция [4], но она измеряет иную геометрию и здесь не применяется. Следуя сравнению методов [5], выбран метод Монте-Карло (200 000 реализаций, антитетические переменные, стандартная ошибка ≤ 0,0008, значения в $[0; \ln 2]$).

Структурная компонента определяется нормированным расстоянием Фробениуса между ковариационными матрицами, корректность которого обоснована в [6]: $D_S(g) = \frac{\|\Sigma_g - \Sigma_0\|_F}{\|\Sigma_g\|_F + \|\Sigma_0\|_F}$ (1). Интегральный показатель информационной сложности $C_I(g) = D_{JS}\left(P_g \| P_0\right) + \beta \cdot D_S(g)$ (2), где β – весовой коэффициент, определяемый адаптивно из условия равного вклада компонент на опорном кластере: $\beta = \frac{\sigma(D_{JS})}{\sigma(D_S)}$ (3), где $\sigma\left(D_{JS}\right)$ и $\sigma(D_S)$ – стандартные отклонения компонент по бутстрэпу опорного кластера (100 случайных разбиений пополам, 2000 повторностей), дающему 95 %-й интервал $\beta \in [0{,}194;\ 0{,}334]$; порядок групп по C_I сохраняется при $\beta \in [0{,}117;\ 1{,}016]$, то есть интервал целиком лежит в зоне устойчивости. Доля $\rho_S = \beta \cdot D_S(g) / C_I(g)$ задаёт «информационный портрет» группы: малые значения отвечают сдвигу уровня, большие – перестройке структуры связей.

Расчёты и результаты. Из архивного среза (4576 записей) отобраны модели с полным набором метрик и раскрытым числом параметров; исключены помеченные сообществом и слитые. Итоговый корпус – 3851 модель, что превышает выборку [3] на два порядка. Опорный кластер – 1047 моделей, процедура (3) дала $\beta = 0{,}254$. Группа свыше 80 млрд (16 моделей) объединена с предыдущей: оценка ковариационной матрицы по шести шкалам требует большей выборки.

Таблица*

Информационная сложность групп моделей ИИ по данным [1]

Группа по X_1, млрд	N моделей	D_{JS}	D_S	C_I	ρ_S
< 3	741	0,399	0,578	0,545	0,27
3–8 (опорная)	1047	0,000	0,000	0,000	–
8–15	1684	0,296	0,165	0,338	0,12
15–40	210	0,325	0,244	0,387	0,16
> 40	169	0,448	0,151	0,487	0,08

* – составлено авторами. D_S по корреляционным матрицам: 0,187; 0,000; 0,136; 0,086; 0,057.

Поведение C_I как меры удаления – свойство конструкции, а не эмпирический закон; содержательно значимо распределение групп по величине и составу отклонения. Максимум достигается на группе менее 3 млрд: $C_I = 0{,}545$ против $0{,}487$ у группы свыше 40 млрд при преимущественно структурном отклонении ($\rho_S = 0{,}27$ против $\leq 0{,}16$). Проверка масштабной инвариантности ограничивает этот вывод: при пересчёте по корреляционным матрицам (значения под таблицей) преимущество группы менее 3 млрд по D_S сокращается с 2,4 до 1,4 раза, доля ρ_S сравнивается со следующей группой (0,11 против 0,10), а максимум C_I смещается к группе свыше 40 млрд – структурное отличие малых моделей в значительной мере объясняется разбросом дисперсий шкал.

Второй результат независим от конструкции показателя и опирается только на регрессионный анализ. Регрессия среднего балла по $\log_{10} X_1$ даёт наклон 13,35 п.п. на порядок при $R^2 = 0{,}401$; логистическая аппроксимация с асимптотой 52,1% повышает R^2 до 0,418. Точка структурного сдвига не задавалась, а оценивалась перебором 60 кандидатов с 15%-м отсечением по краям; максимум приходится на $\approx$ 13,7 млрд параметров. Поскольку точка оценена по тем же данным, критические значения Фишера неприменимы, и значимость sup-$F = 219{,}2$ проверена бутстрэпом при нулевой гипотезе об отсутствии разрыва (299 повторностей, превышений нет, $p < 0{,}004$). Это подтверждает смену режима масштабирования, высказанную в [3] по выборке из десяти моделей.

Новизна и применимость. Показатель [2] перенесён на статический ансамбль: роль нормального режима играет опорный кластер, текущего состояния – сопоставляемая группа. Декомпозиция (3) позволяет оценить, какая часть отклонения группы обусловлена различием дисперсий шкал, а какая – перестройкой корреляционной структуры; для группы < 3 млрд доминирует первая. Это означает качественный, а не количественный характер потерь при переносе решений с базового сегмента на меньшие модели; для групп свыше 8 млрд, напротив, допустим пересчёт ожидаемого качества по уровневой поправке. Тот же аппарат применим к последовательным срезам рейтингов.

Заключение. Предложена процедура сравнительной оценки сложности моделей ИИ с автоматическим весом компонент. На корпусе из 3851 модели

показано, что структурное отличие малых моделей в значительной мере обусловлено различием дисперсий шкал; независимо подтверждён структурный сдвиг около 14 млрд параметров, ранее зафиксированный как предварительный сигнал.

Список литературы

1. Open LLM Leaderboard. – Текст: электронный // Hugging Face : [сайт]. – URL: https://huggingface.co/spaces/open-llm-leaderboard/open_llm_leaderboard (13.09.2026).
2. Звягинцева А. В. Интегральный показатель информационной сложности многомерных систем на основе JS-дивергенции и структурного расстояния / А. В. Звягинцева, А. Р. Бражников // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2026. – № 2. – С. 69–85. – DOI 10.5281/zenodo.20799924. – EDN ALDTAO.
3. Звягинцева А. В. К вопросу о феноменологических закономерностях развития больших языковых моделей: возможен ли аналог закона Мура? / А. В. Звягинцева, А. Р. Бражников // Проблемы искусственного интеллекта. – 2026. – № 3(42). – С. 62–74.
4. Nielsen F. On the Jensen–Shannon Symmetrization of Distances Relying on Abstract Means / F. Nielsen // Entropy. – 2019. – Vol. 21, No. 5. – Art. 485. – DOI 10.3390/e21050485.
5. Hershey J. R. Approximating the Kullback–Leibler Divergence Between Gaussian Mixture Models / J. R. Hershey, P. A. Olsen // 2007 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP '07). – Honolulu, HI, USA, 2007. – Vol. 4. – P. IV-317–IV-320. – DOI 10.1109/ICASSP.2007.366913.
6. Biscay R. Cross-Validation of Covariance Structures Using the Frobenius Matrix Distance as a Discrepancy Function / R. Biscay, L. M. Rodríguez, E. Díaz-Francés // Journal of Statistical Computation and Simulation. – 1997. – Vol. 58, No. 3. – P. 195–215. – DOI 10.1080/00949659708811831.

УДК 004.627

ИССЛЕДОВАНИЕ ВЛИЯНИЯ АЛГОРИТМОВ СЖАТИЯ НА ПРОИЗВОДИТЕЛЬНОСТЬ КОЛОНОЧНОГО ФОРМАТА PARQUET В РАСПРЕДЕЛЕННОЙ СРЕДЕ APACHE SPARK

Истратова Е.Е., канд. техн. наук, доц., ORCID 0000-0001-9759-2249,
Пересыпкин С.В., Рыжова Л.В.
ФГБОУ ВО «Новосибирский государственный технический университет»,
г. Новосибирск, РФ
istratova@corp.nstu.ru, peressypkinwork@gmail.com, lyubaryzhova93@gmail.com

Введение. В настоящее время наблюдается стремительный рост объемов больших данных (Big Data) и для них требуются оптимальные сочетания способов хранения и обработки в аналитических хранилищах (Data Lake). Индустриальным стандартом для фреймворков обработки данных, таких как Apache Spark стал колоночный формат Parquet. Он

обеспечивает исключение ненужных колонок и фильтрацию на уровне метаданных. Но выбор кодека сжатия данных остается индивидуальным и напрямую влияет на ввод-вывод, дисковое пространство и процессор [1].

В процессе разработки архитектуры данных разработчикам часто приходится сталкиваться с выбором приоритета коэффициента сжатия и скорости декомпрессии. В связи с этим, в качестве основной гипотезы было предложено, что алгоритм Snappy является более предпочтительным в условиях высокой скорости работы CPU, при этом ZSTD может стать новым стандартом индустрии [2].

Цель исследования заключалась в проведении сравнительного анализа архитектурных особенностей популярных алгоритмов сжатия при использовании в Parquet и выделении их ключевых преимуществ и недостатков для оптимизации работы Apache Spark.

Основная часть. Parquet – это бинарный, колоночно-ориентированный формат хранения данных, изначально созданный для экосистемы Hadoop. Формат Parquet организует данные на диске в виде групп строк, внутри которых значения каждого столбца сжимаются индивидуально. Физическая структура Parquet делится на три основных элемента: группы строк, столбцы, страницы. Так как значения в пределах одного столбца имеют одинаковый тип данных и часто повторяются, Parquet перед сжатием применяет кодирование на уровне формата, и только после этого к сформированным страницам данных применяется алгоритм сжатия. Основные алгоритмы сжатия, которые применяют в индустрии это: Snappy, Gzip, ZSTD [3].

Snappy – разработан компанией Google, предназначен для скоростной распаковки и скоростного сжатия, при этом может иметь более объемный итоговый файл по сравнению с другими алгоритмами. Snappy основан на модфикации алгоритма LZ77, но не использует кодирование Хаффмана на финальном этапе, что избавляет систему от дополнительных вычислений. Преимуществами алгоритма являются высокая скорость сжатия и минимальное влияние на сквозную задержку. В связи с этим, данный алгоритм применяется в высокопроизводительных системах, где низкая задержка является абсолютным приоритетом.

Gzip (GNU Zip) – алгоритм сжатия общего назначения, основанный на алгоритме DEFLATE. Суть работы сводится к определению повторяющихся фрагментов текста, замене их ссылками на ранее встречаемые эквиваленты, после чего осуществляется сжатие распространенных символов меньшим количеством бит. Алгоритм обеспечивает сильное сжатие, особенно на текстовых и строковых данных, но требует значительного времени, поэтому его целесообразно применять в системах с минимальным объемом хранилища и низкой пропускной способностью сети.

ZSTD (Zstandard) – современный алгоритм сжатия с высокой производительностью (не ниже, чем у Snappy) и значениями коэффициентов

сжатия, как у Gzip, в зависимости от выбранного уровня сжатия. Также ZSTD позволяет настраивать уровень сжатия, комбинирует быстрый поиск совпадений с энтропийным кодированием на основе конечных состояний энтропии и энтропийным системами асимметричных чисел.

Сжатие в Parquet влияет на два важных параметра: объем данных и скорость обработки. Данные сжимаются, что снижает затраты на их хранение и уменьшает нагрузку на систему ввода-вывода. При этом, несмотря на то, что сжатие требует дополнительных вычислительных ресурсов, оптимальный алгоритм может ускорить процессы чтения и записи. Сильно сжатые данные, как правило, снижают нагрузку на диски и сети, а также ускоряют передачу данных между системами. В таблице приведены результаты сравнительного анализа алгоритмов сжатия [4,5].

Таблица

Результаты сравнительного анализа алгоритмов сжатия

Алгоритм	Степень сжатия	Скорость	Загрузка процессора
Gzip	Высокая (~75%)	Низкая	Высокая
ZSTD	Высокая (~72%)	Средняя	Средняя
Snappy	Средняя (~68%)	Высокая	Низкая

Таким образом, на основе результатов сравнительного анализа можно выделить более эффективные алгоритмы для реализации определенных сценариев. Так, Gzip подходит только для «холодных» данных, которые практически не считываются, так как имеет максимальную степень сжатия. Однако этот вариант отличается высокой нагрузкой на процессор, что при активной аналитической работе в Spark является неэффективным. Индустриальным стандартом в Apache Spark по умолчанию является Snappy. В аналитике больших данных ключевым недостатком данного алгоритма является низкая скорость работы процессора и высокие значения задержки сети. Snappy сжимает данные достаточно хорошо, при этом достаточно быстро считывает и распаковывает данные, не нагружая процессор кластера.

Несмотря на то, что Snappy является индустриальным стандартом, при проектировании современной архитектуры данных на Spark, ZSTD будет лучшим выбором, так как степень сжатия у него выше (объем файлов меньше на 20-30 %), но при этом высокая скорость распаковки, сопоставимая со Snappy. Одним из важных преимуществ ZSTD является наличие уровней сжатия, поэтому, начиная с последних версий Spark и Parquet, именно ZSTD становится новым стандартом.

Заключение. В результате выполненного сравнительного анализа трех алгоритмов сжатия предложенная гипотеза была подтверждена. На данный момент индустриальным стандартом является Snappy, так как

позволяет проводить оперативную работу с данными, несмотря на это, ZSTD является более эффективным решением.

Список литературы

1. Дронов, А. Н. Алгоритмы сжатия данных в информационно-измерительных системах / А. Н. Дронов, А. В. Левенец // Вестник ТОГУ. – 2022. – № 2 (65). – С. 15-22.
2. Войтенко, М. С. Сравнительный анализ современных алгоритмов сжатия данных без потерь в составе программных решений / М. С. Войтенко, А. С. Войтенко, В. В. Сафронов // Вестник ВГТУ. – 2023. – № 6. – С. 76-80.
3. Виноградова, М. С. Сжатие данных. Алгоритм Хаффмана / М. С. Виноградова, О. С. Ткачева // Modern European Researches. – 2022. – № 3. – С. 60-69.
4. Ахмедов, Э. Р. Формат Parquet: обзор структуры и методы оптимизации для высокой производительности в распределённых системах / Э. Р. Ахмедов, И. В. Хлудов // Universum: технические науки. – 2025. – № 4 (133). – С. 3-7.
5. Равский, А. А. Современные тенденции развития алгоритмов сжатия / А. А. Равский, А. В. Левенец // Вестник ТОГУ. – 2021. – № 3 (62). – С. 29-36.

УДК 004.94: 536.41

ПРОБЛЕМЫ ИДЕНТИФИКАЦИИ АКСИОМАТИКИ МОДЕЛЕЙ ДИНАМИКИ ФИЗИЧЕСКИХ ПРОЦЕССОВ В ЗАДАЧАХ ВЫЧИСЛИТЕЛЬНОГО ЭКСПЕРИМЕНТА

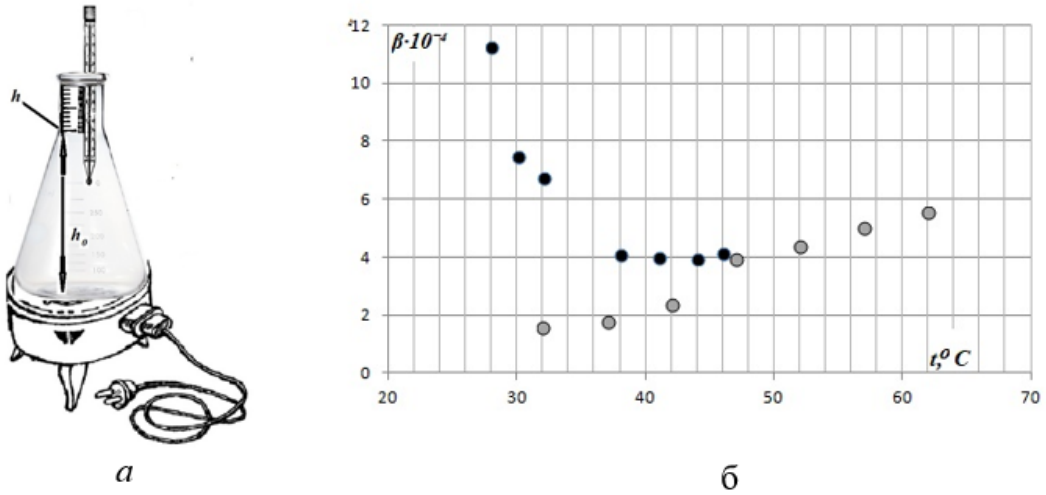
Камалова Н.С., канд. физ.-мат. наук, доц., ORCID 0000-0001-8293-8593,
Внукова С.В., канд. физ.-мат. наук, ORCID 0000-0001-6889-9233,
Евсикова Н.Ю., канд. физ.-мат. наук, доц., ORCID 0000-0001-5288-0140,
Матвеев Н.Н., д-р физ.-мат. наук, проф., ORCID 0000-0001-9195-9580,
Лисицын В.И., канд. физ.-мат. наук, доц., ORCID 0000-0002-2148-1988
ФГБОУ ВО «Воронежский государственный лесотехнический университет имени Г.Ф. Морозова», г. Воронеж, РФ
rcamel@yandex.ru, svvnukova@mail.ru

Введение. Изначально в основе вычислительного эксперимента лежала знаменитая триада академика Самарского: модель, алгоритм, программа (код) [1]. Такой подход хорошо зарекомендовал себя при исследовании процессов, для которых накоплен обширный и согласованный экспериментальный материал. В настоящий момент в прикладной науке под моделью принято понимать дифференциальные уравнения рабочих процессов в модернизируемой аппаратуре и влияние на их параметры условий эксплуатации, поэтому активно развиваются численные методы их решения [2, 3]. С развитием компьютерных технологий актуальными становятся проблемы технологии вычислительных экспериментов, особенно идентификации модельных уравнений и реальных процессов [4].

Последнее особенно интересно в связи с развитием искусственного интеллекта, поскольку разработка методов адекватного выбора модели способствует расширению сферы его применения. Однако при переходе к слабоформализованным средам и условиям, где исходные данные обладают внутренней противоречивостью, возникает проблема корректной идентификации аксиоматики модели. Это особенно значимо для компьютерных систем, ориентированных на автоматизированную обработку экспериментальных данных и поддержку принятия решений, поскольку качество таких систем напрямую определяется полнотой и достоверностью заложенных в них представлений об объекте.

Целью работы является анализ проблем идентификации аксиоматики модели динамики физических процессов на примере теплового расширения воды при нагревании и оценка того, насколько существующие модельные представления, используемые в вычислительном эксперименте, отражают реальное многообразие наблюдаемых сценариев.

Основная часть. В работе использовались результаты экспериментов по мониторингу теплового расширения воды на установке, изображенной на рисунке (а).



а б

Рис. Исследование изменений коэффициента теплового расширения от температуры: а – схема установки [5], б – результаты испытаний

Коэффициент теплового расширения рассчитывался по соотношению:

$$\beta_t = \frac{3h}{h_0(t-t_0)}\left[1+\frac{D}{d}+\left(\frac{D}{d}\right)^2\right]^{-1}, \qquad (1)$$

где D и d – диаметр дна и горлышка колбы; t_0 – температура окружающего воздуха; h_0 – начальная высота уровня воды в колбе.

Результаты испытаний, представленные на рисунке (б), отражают две различные динамики коэффициента расширения воды (β) при нагревании в диапазоне температур 30-60 °С при практически одинаковых внешних

условиях ($t_0 \approx 25$ °C). В большинстве случаев (серые маркеры) наблюдается ступенчатое возрастание коэффициента, что согласуется с табличными данными. Однако примерно в 30 % опытов зафиксирована иная зависимость (черные маркеры): при нагревании значение β сначала существенно снижается. Подобный эффект наблюдался, когда колба с водой перед испытанием отстаивалась несколько суток. Это позволяет предположить образование на поверхности воды пленки, коэффициент расширения которой примерно на порядок превышает аналогичный параметр для воды. При нагревании пленка разрушается, что и приводит к первоначальному уменьшению измеряемого коэффициента. Таким образом, динамика теплового расширения капельных сред отражает изменение состава, как минимум, поверхностного слоя, особенно при наличии примесей.

Для компьютерных систем и алгоритмов прогнозирования этот результат означает, что, если обучающая выборка построена только по табличным данным, то в ней отсутствует информация о второй динамике (черные маркеры), на которую приходится около 30 % наблюдений. Модель, хорошо согласованная с обучающими данными, воспроизводит один режим поведения объекта и при работе с реальными данными может давать систематическое смещение оценок. Поэтому при идентификации моделей физических процессов важно учитывать неоднородность экспериментальных данных и предусматривать возможность выделения скрытых режимов функционирования объекта.

Заключение. Если модельные соотношения формулируются только по табличным данным или по результатам регрессии, то до 30 % возможных ситуаций остаются вне рассмотрения. Для вычислительного эксперимента, который позволяет прогнозировать поведение объектов без дорогостоящих натурных испытаний [6], это означает потерю одного из его основных преимуществ – достоверность представлений об исследуемом процессе. Поэтому при построении базовой аксиоматики модели идентификация ситуации должна опираться на более полное описание наблюдаемых режимов.

Список литературы

1. Самарский, А. А. Математическое моделирование: Идеи. Методы. Примеры: монография / А. А. Самарский, А. П. Михайлов. – 2-е изд., испр. – Москва: ФИЗМАТЛИТ, 2005. – 320 с. – ISBN 5-9221-0120-X.
2. Веретенников, В. Н. Вычислительные эксперименты при решении разностных уравнений для обыкновенных дифференциальных уравнений: Учебно-методическое пособие / В. Н. Веретенников, В. А. Большаков. – Санкт-Петербург: РГГМУ, 2019. – 60 с. – EDN MNQQNM.
3. Плохотников, К. Э. Разработка и обоснование нового подхода к методу математического моделирования (проблема предметной множественности моделей и анализ адекватности их целям исследования): специальность 05.13.18 «Математическое моделирование, численные методы и комплексы программ»:

диссертация на соискание ученой степени доктора физико-математических наук / Плохотников Константин Эдуардович. – Москва, 2013. – 165 с. – EDN SUMXFB.
.4. Афанасьева, Н. Ю. Вычислительные и экспериментальные методы научного эксперимента: учебное пособие для студентов высших учебных заведений / Н. Ю. Афанасьева. – Москва: КноРус, 2010. – 330 с. – ISBN 978-5-406-00176-9. – EDN QXZPWX.
5. Механика жидкости и газа: лабораторный практикум / Н. С. Камалова, Н. Ю. Евсикова, В. И. Лисицын и др. – Воронеж: Воронежский государственный лесотехнический университет им. Г. Ф. Морозова, 2016. – 62 с. – EDN YLWRKZ.
6. К вопросу о возможностях вычислительного эксперимента / Н. С. Камалова, Н. Н. Матвеев, Н. Ю. Евсикова и др. // Донецкие чтения 2022: образование, наука, инновации, культура и вызовы современности: Материалы VII Международной научной конференции, посвящённой 85-летию Донецкого национального университета, Донецк, 27–28 октября 2022 года / Под общей редакцией С. В. Беспаловой. Том 2. – Донецк: Донецкий национальный университет, 2022. – С. 188-190. – EDN OIMZAB.

УДК 004.65

ФУНКЦИОНАЛЬНОЕ МОДЕЛИРОВАНИЕ В ПРОЦЕССЕ РАСЧЕТА ЭКОНОМИЧЕСКОЙ ЭФФЕКТИВНОСТИ ПРОЕКТА КОМПЛЕКСНОЙ АВТОМАТИЗАЦИИ ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ ТКАЦКОЙ ФАБРИКИ

Караваева Э.А., ORCID 0009-0003-7501-4626,
Ковтун И.И., канд. техн. наук, доц., ORCID 0009-0005-8222-5290
ФГБОУ ВО «Московский технический университет связи и информатики»,
г. Москва, РФ
i.i.kovtun@mtuci.ru

Введение. Лёгкая промышленность является одной из основных отраслей экономики Российской Федерации с рынком более 2,6 трлн. руб. и ежегодным ростом 10–12 %. При этом, в 2025 г. доля отечественных товаров достигла 50 % [1]. Ключевое место в отрасли занимают ткацкие предприятия, рентабельность которых зависит от рационального использования ресурсов и эффективного управления технологическими процессами.

Как правило, в качестве специального программного обеспечения российские текстильные предприятия используют типовые конфигурации «1С», которые позволяют учесть технологические операции, но не поддерживают планирование и логистику. Более того, раздельное использование функциональных и реляционных моделей, традиционно лежащих в основе проектирования подобных программ, не позволяет

должным образом обосновать экономическую целесообразность проекта комплексной автоматизации [2], [3].

Целью исследовательской работы является разработка способа интеграции стоимостной интерпретации функциональной модели IDEF0 [4] и показателей NPV, IRR, ROI в процессе оценки экономической эффективности проекта комплексной автоматизации технологических процессов ткацкой фабрики.

Основная часть. Разработана функциональная модель IDEF0, отражающая торгово-складскую и логистическую деятельность ткацкой фабрики по принципу AS-IS. В качестве примера целесообразно рассмотреть процесс отгрузки готовой продукции как наиболее критичный с точки зрения координации материальных и информационных потоков. При этом, фрагмент декомпозиции представлен на рис. 1. На основе анализа функциональной модели разработана реляционная модель данных, отражающая информационные потоки предприятия – обработку заказов, учёт сырья, складские операции и отгрузку продукции. Фрагмент указанной модели представлен на рис. 2.

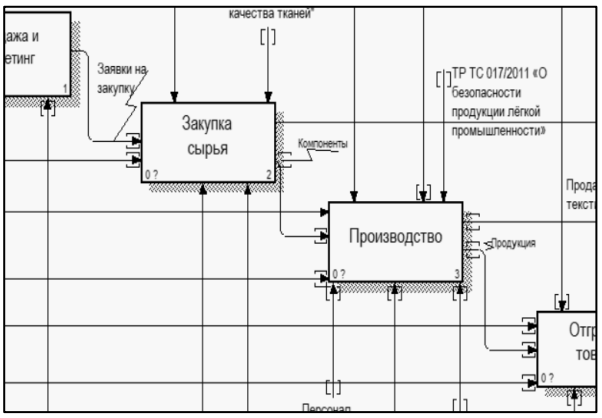


Рис. 1. Фрагмент декомпозиции торгово-складской и логистической деятельности в нотации IDEF0

Интеграция функциональной и реляционной моделей достигнута посредством языка SQL. С его помощью определены таблицы базы данных, см. пример создания таблицы MOVEMENT_OF_GOODS в Листинге 1, а также разработаны шаблоны запросов, структура которых определяется соответствующей функцией IDEF0-модели, а конкретные таблицы и столбцы задаются даталогической моделью [5]. Для выявления клиентов с растущим спросом, см. Листинг 2, разработан фрейм с использованием соединения таблиц, общего табличного выражения, оконной функции и коррелированного подзапроса.

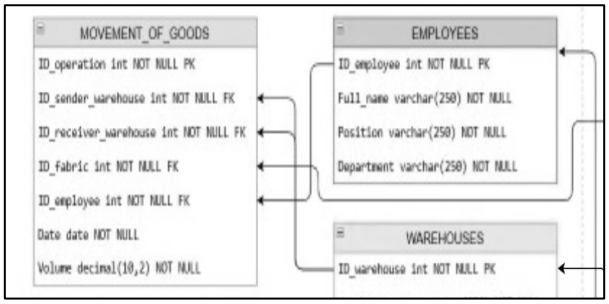


Рис. 2. Фрагмент реляционной модели информационных потоков ткацкой фабрики

Листинг 1. Фрагмент кода создания таблицы базы данных

```
CREATE TABLE MOVEMENT_OF_GOODS (
  ID_operation INT PRIMARY KEY, ID_fabric INT NOT NULL REFERENCES FABRICS,
  ID_sender_warehouse INT NOT NULL REFERENCES WAREHOUSES,
```

```
  ID_receiver_warehouse INT NOT NULL REFERENCES WAREHOUSES,
  Volume DECIMAL(10,2) NOT NULL CHECK (Volume > 0),
  CHECK (ID_sender_warehouse <> ID_receiver_warehouse));
```

Листинг 2. Фрагмент SQL-фрейма анализа спроса клиентов

```
WITH trend AS (
  SELECT ID_client, ID_fabric, DATE_TRUNC('month', Order_date) AS mth,
         SUM(Volume) AS vol, LAG(SUM(Volume)) OVER (PARTITION BY
         ID_client, ID_fabric ORDER BY MIN(Order_date)) AS prev
  FROM PRODUCTIONS_ORDERS GROUP BY 1, 2, 3)
SELECT c.Company_name, t.ID_fabric, t.mth, t.vol
FROM trend t JOIN CLIENTS c ON c.ID_client = t.ID_client
WHERE t.vol > t.prev AND t.vol > (SELECT AVG(vol) FROM trend x
  WHERE x.ID_client = t.ID_client AND x.ID_fabric = t.ID_fabric);
```

В свою очередь экономическое обоснование проекта комплексной автоматизации строится непосредственно на данных реляционной модели, а именно, для таблиц FABRICS и PRODUCTIONS_ORDERS разработан SQL-фрейм ABC-анализа, ранжирующий типы тканей по вкладу в выручку с накопленной долей, вычисляемой оконной функцией SUM() OVER, и относящий их к группам A, B, C по принципу Парето [6], см. Листинг 3.

Листинг 3. ABC-анализ тканей по вкладу в выручку

```
WITH rev AS (
  SELECT f.Fabric_type,
         SUM(po.Volume * f.Price_per_unit) AS revenue
  FROM PRODUCTIONS_ORDERS po
  JOIN FABRICS f ON f.ID_fabric = po.ID_fabric
  GROUP BY f.Fabric_type)
SELECT Fabric_type, revenue,
  ROUND(SUM(revenue) OVER (ORDER BY revenue DESC) * 100.0 /
        SUM(revenue) OVER (), 2) AS cum_share_pct
FROM rev ORDER BY revenue DESC;
```

Аналогичный фрейм, применённый к анализу оборачиваемости позволяет выявить типы тканей, одновременно относящиеся по выручке к группе C и имеющие низкую оборачиваемость, – именно они формируют экономически необоснованные запасы и наибольшую нагрузку на стоимость хранения. Результаты обоих фреймов используются как источник потока выгод B_t для итоговой оценки эффекта от автоматизации, в т.ч. чистого дисконтированного дохода внутренней нормы доходности IRR и рентабельности инвестиций ROI [6].

$$NPV = \sum \frac{(B_t - C_t)}{(1+r)^t} - I_0,$$

Заключение. В результате исследования построена функциональная модель IDEF0, реляционная модель ткацкой фабрики, проведена их интеграция с применением SQL-фреймов JOIN и CTE, а также разработаны инструменты ABC-анализа и оборачиваемости запасов для расчета NPV, IRR и ROI, что подтверждает эффективность предложенного в [7] функционально-реляционного метода проектирования автоматизированных систем.

Список литературы

1. Воронов С. В. Современные проблемы автоматизации производственной логистики на малых предприятиях / С. В. Воронов // Вестник экономики и промышленности. – 2021. – № 3. – С. 45–49.
2. Ковтун И. И. Теория и практика проектирования государственных информационных систем. Учебное пособие / И. И. Ковтун // 2-е изд., доп. и перераб. – СПб.: Издательство НИЦ АРТ, 2026. – 194 с.
3. Ковтун И. И. Интеграция формальных моделей в процессе комплексной автоматизации и интеллектуализации отечественных тепличных производств / И. И. Ковтун, М. А. Жукова, М. А. Мутина // Экономика и управление: проблемы, решения. – 2026. – Т. 7. – № 7. – С. 208–217.
4. РД 50.1.028-2001. Методология функционального моделирования IDEF0. Руководящий документ. Издание официальное. – М.: ИПК Издательство стандартов, 2000. – 75 с.
5. Караваева Э. А. Применение интеллектуальных инструментов в процессе разработки автоматизированной системы управления информационными потоками и производственными процессами ткацкой фабрики / Э. А. Караваева, И. И. Ковтун // REDS: Телекоммуникационные устройства и системы. – 2026. – № 1 – С. 17-23.
6. Ковалев В. В. Методы оценки инвестиционных проектов / В. В. Ковалев. – М.: Финансы и статистика, 1998. – 144 с.
7. Ковтун И. И. Функционально-реляционный анализ вариантов автоматизации сложных организационно-технических систем. Монография / И. И. Ковтун. – СПб.: Изд-во НИЦ АРТ, 2024. – 214 с.: ил.

УДК 004.8

ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В КОМПЬЮТЕРНЫХ СИСТЕМАХ ПОДДЕРЖКИ УЧЕБНОЙ И НАУЧНОЙ ДЕЯТЕЛЬНОСТИ ТЕХНИЧЕСКОГО ВУЗА

Каюмов А.Ф., ORCID 0009-0006-5664-5184,
Рахимова Г.С., канд. экон. наук, доц.,ORCID 0000-0003-2936-8055
ФГБОУ ВО «Казанский национальный исследовательский технический университет – Казанский авиационный институт им. А. Н. Туполева», г. Казань, РФ
kai@kai.ru

Введение. Генеративные языковые модели вошли в учебную практику студентов технических вузов быстрее, чем вузы успели определить правила работы с ними: опросы показывают, что студенты применяют такие инструменты для поиска, обработки и анализа информации. Ответ модели при этом выглядит убедительно независимо от того, верен он или нет, поэтому практический интерес представляет не перечень возможностей таких моделей, а вопрос, какие операции целесообразно передавать им в составе компьютерной системы поддержки учебной и научной деятельности, а какие должны оставаться за человеком.

Основная часть. Цель работы – определить, насколько пригодны ответы генеративной модели для четырёх типовых операций учебной и научной работы, и какие ограничения необходимо учитывать при её включении в компьютерную систему поддержки. Под компьютерной системой поддержки понимается цифровая среда, включающая пользовательский интерфейс, модуль генеративного искусственного интеллекта (ИИ), средства работы с учебными и научными материалами и инструменты проверки результатов. Генеративный ИИ рассматривается в ней не как автономный сервис, а как элемент управляемого процесса, предполагающего верификацию содержания, ограничение доступа к данным и контроль корректности ответов. Работа опирается на публикации 2024–2026 годов по применению генеративного ИИ в высшем образовании [1–5].

Проверка выполнена 5 октября 2026 г. на языковой модели GigaChat. Были сформированы четыре группы заданий: работа с научными публикациями, подготовка учебно-методических материалов, структурирование научного текста и задачи программирования – по десять заданий в каждой, сформулированных близко к реальным учебным. Дополнительно дано пять заданий на проверку фактической точности: определение действующего стандарта, расчёт вероятности и предсказание поведения программного кода. Всего выполнено 45 заданий, каждое – в отдельном диалоге, чтобы модель не опиралась на предыдущие ответы. Ответ относился к одной из трёх категорий: пригоден после небольшой правки, неполный, непригодный. Пригодным считался ответ, содержание которого верно и не требует проверки фактов; оценку выставлял автор работы.

Из 40 основных заданий пригодными после правки оказались 19 (47,5 %), неполными – 13, непригодными – 8. Доля пригодных ответов составила от 40 до 60 %: 5 из 10 – для учебно-методических материалов, по 4 из 10 – для работы с научными публикациями и структурирования научного текста и 6 из 10 – для программирования. Последнее направление оказалось наиболее надёжным: корректность решения проверяется запуском программы, и ошибку легко обнаружить. Наименее надёжными были работа с публикациями и структурирование текста, где ответ верен лишь при соблюдении оговорок исходного материала.

Наиболее серьёзные дефекты относились не к качеству формулировок, а к содержанию: модель достраивала отсутствующие сведения. В задании сделать обзор трёх источников она выдала ссылки Smith J. (2024), Chen L. et al. (2024), Иванова А.В. (2024) и статистику: 150 проанализированных статей, 70 %, снижение отсева на 12 %, хотя ни один источник не задавался и найти их по приведённым данным невозможно. В задании определить методологию статьи, которая не предоставлялась, модель уверенно назвала «квазиэкспериментальный» план с проверкой «с помощью t-критерия Стьюдента или ANOVA». В задании сформулировать цель и три задачи курсовой работы был получен план педагогического эксперимента

с контрольной и экспериментальной группами. Такие ответы опасны тем, что выглядят полными: ссылки оформлены по образцу, статистика приведена с точностью до процента, выводы сформулированы уверенно.

Три ответа из пяти признаны пригодными после правки, один неполным и один непригодным. Ошибок в расчётах не выявлено: значение стандартного ускорения свободного падения (9,80665 м/с²) указано верно, вероятность в задаче на выбор без возвращения (3/28 ≈ 0,107) вычислена правильно. Однако в одном ответе числовое значение сопровождалось «артефактом», что указывает на смешение частей разных ответов при генерации.

Генеративный ИИ уместен на этапе черновой обработки материала, но не как источник готовых фактов и ссылок. В состав системы целесообразно включать проверку ссылок и числовых значений, ограничение доступа к закрытым материалам, конспектирование запросов и обязательное подтверждение результата пользователем. Для технического вуза отдельно значимы риски генерации ошибочного программного кода и передачи научно-технической информации во внешние сервисы [2]. Результативность применения зависит от характера учебного сценария и наличия педагогического сопровождения [5].

Проверка выполнена на одной модели и одном наборе заданий в течение одного дня, сравнение с другими моделями не проводилось. Оценка ответов выставлена автором и носит субъективный характер. Вопросы стоимости вычислительных ресурсов, защиты персональных данных и интеграции с действующими информационными системами вуза не рассматривались.

Заключение. Генеративный ИИ применим в компьютерной системе поддержки учебной и научной деятельности технического вуза прежде всего на этапе черновой обработки материала [1; 3]. Проведённая проверка из 45 заданий показала, что пригодными после небольшой правки оказались 47,5 % ответов, а основная причина отбраковки – не качество формулировок, а вымышленные ссылки, достроенные детали исследования, подмена поставленной задачи и неполный учёт условий. Наиболее надёжным направлением оказалась работа с программным кодом, поскольку её результат проверяется запуском программы. Проверка фактов, ссылок и работоспособности кода остаётся за пользователем.

Список литературы

1. Litvinova E. Large Language Models as a Tool for Personalizing and Adapting Education in the Development Strategy of a Technical University / E. Litvinova, M. Frantsuzov, A. Chesalov // Journal of Monetary Economics and Management. – 2026. – № 6. – С. 96–102. – DOI 10.26118/2782-4586-2026-96-102.
2. Bittle K. Generative AI and Academic Integrity in Higher Education: A Systematic Review and Research Agenda / K. Bittle, O. El-Gayar // Information. – 2025. – Vol. 16, No. 4. – Article 296. – DOI 10.3390/info16040296.

3. Romero M., Reyes J., Kostakos P. Generative Artificial Intelligence in Higher Education // Creative Applications of Artificial Intelligence in Education / ed. by A. Urmeneta, M. Romero. – Cham: Palgrave Macmillan, 2024. – P. 129–143. – DOI 10.1007/978-3-031-55272-4_10.
4. Nygren Å. Exploring student use of generative AI in higher education: A dual-institutional study / Å. Nygren, A. Eriksson, J. Sjöberg [et al.] // Education and Information Technologies. – 2026. – DOI 10.1007/s10639-026-14100-2.
5. Gu J. Effects of GenAI Interventions on Student Academic Performance: A Meta-Analysis / J. Gu, Z. Yan // Journal of Educational Computing Research. – 2025. – Vol. 63, № 6. – С. 1460–1492. – DOI 10.1177/07356331251349620.

УДК 621

ФАКТОРЫ, СПОСОБОСТВУЮЩИЕ ПЕРЕХОДУ К КОНЦЕПЦИИ ИНДУСТРИЯ 5.0 В МАШИНОСТРОЕНИИ

Клубаев А.С., Стаценко А.А., канд. техн. наук, доц.
МОУВО «Белорусско-Российский университет», г. Могилев, Республика Беларусь
klubaev2002@mail.ru

Введение. Неоспоримым фактом является то, что появление новейших технологий последовательно приводит к глобальным структурным изменениям сфер деятельности человека, в которых прорыв был осуществлен. Одним из таких прорывов в машиностроении стало развитие концепции Индустрии 4.0 или Четвертой промышленной революции. Главными задачами системы являлись автоматизация, цифровизация и минимизация человеческого фактора, который рассматривался в качестве источника ошибок и фактора снижения скорости производства. Фокус исключительно на повышении производительности и минимизации издержек привел к росту социальной напряженности, экологическим рискам и уязвимости жестко оптимизированных систем. Ответом на эти вызовы стало формирование новой парадигмы – Индустрии 5.0.

Основная часть. Индустрия 4.0 позволила достичь беспрецедентного уровня автоматизации, оптимизации и прозрачности производственных процессов, а именно, использование датчиков с системами искусственного обучения позволяет проводить анализ изделий в процессе их изготовления. Алгоритмы определяют параметры режимов резания, необходимость смены режущего инструмента, шероховатость поверхности и другие параметры.

Использование систем искусственного интеллекта не ограничивается исключительных их применением в средствах контроля изделий. Анализ чертежей и 3D-моделей, получаемых параметров поверхностей позволяет использовать эти системы для подготовки кода. Алгоритмы способны

определять необходимые операции, траекторию инструмента, параметры обработки, а также корректировать программу за счет самообучения.

Благодаря внедрению цифровых двойников производится виртуализация и аналитика данных: можно моделировать процесс обработки деталей и изменять режимы обработки на каждой стадии, проводить тесты на готовом изделии, проверять работу оборудования.

Все эти преимущества унаследовала и система Индустрия 5.0, взяв лучшее из предыдущего опыта, однако новая парадигма вернула человека в производство. Пятая промышленная революция основана на объединении людей, оборудования и сетевых технологий в единую систему, где технологии работают не вместо человека, а вместе с ним, решая сложные производственные задачи, адаптируясь к внешним вызовам.

Центральным понятием Индустрии 5.0 является человекоцентричность – подход, переориентированный с технологий на людей и природу, при котором в основу производственного процесса ставятся потребности человека. В результате происходит переосмысление ценности работника в компании: он рассматривается через призму инвестиций, а не издержек. [1]

Глобальные кризисы продемонстрировали, что выживаемость бизнеса напрямую зависит от его адаптивности. Жизнестойкость предполагает создание гибких производственных систем и цепочек поставок, способных шоки, прогнозировать риски с помощью предиктивной аналитики и быстро перестраиваться в условиях форс-мажорных обстоятельств.

Использование инновационных подходов позволяет добиться эффективного использования ресурсов, минимизировать отрицательное взаимодействие на окружающую среду.

Главной технологической основой Индустрии 5.0 является коллаборативная робототехника.

Коллаборативный робот (кобот) представляет собой автоматизированное устройство, которое запрограммировано на выполнение различных производственных задач совместно с работником. Кобот снабжается высокочувствительными датчиками, сенсорными технологиями, компьютерным зрением, системой когнитивных вычислений (технологии нового поколения, которые направлены на решение проблем путем имитации мыслительного процесса человека) для распознавания нахождения рядом людей, что делает совместное использование рабочего пространства безопасным. [1]

Главным преимуществом коллаборативных роботов является их универсальность. В отличие от традиционных промышленных автоматизированных систем, которые требуют сложной перенастройки, коботы могут легко адаптироваться к новым задачам. [2]

Основные возможности:

– благодаря модульной конструкции устройство можно оснастить быстросменными приспособлениями различного назначения.

– благодаря своей простоте наладчик или оператор способны самостоятельно писать алгоритм работы или код управляющей программы.

В процессе работы датчики постоянно сканируют пространство, а встроенные алгоритмы вычисляют координаты и направления движения. Если сотрудник меняет темп или направление работы, робот мгновенно корректирует свою траекторию.

Взаимодействие человека и робота в этой среде описывается понятием Human-Robot Interaction (Человеко-машинное взаимодействие) – междисциплинарная область на стыке робототехники, искусственного интеллекта, психологии, дизайна и эргономики, цель которой заключается в безопасном взаимодействии робота и человека, интеграции роботов в общество, в экономику и промышленность.

Заключение. Концепция модели Индустрия 4.0 исчерпала потенциал роста. Выяснилось, что автоматизированные линии лишены важнейшего качества – гибкости, которая необходима для создания уникальной продукции. Именно синергия машин, человека и современных технологий способна удовлетворить новые рыночные реалии.

Переход к Индустрии 5.0 требует трансформации не только технологического оборудования, но и образования. Необходимо в процессе обучения не только рассматривать традиционные системы, но и добавлять современные технологии в виде использования искусственного интеллекта, цифровых двойников, обучения необходимым языкам программирования, важности человеко-машинного взаимодействия.

Индустрия 5.0 представляет собой закономерный этап эволюции производства. Она не является отказом от цифровизации, а выступает её качественным переосмыслением. Вернув человека в центр производственных процессов – формируется новый вид промышленности, где совмещаются преимущества человека и инновационных технологий. Особенно актуальна модель Индустрии 5.0 в машиностроении, где важно сохранить интеллектуальный труд инженеров и обеспечить высокую степень автоматизации.

Исследования данной концепции проводятся на кафедре «Технология машиностроения» Белорусско-Российского университета в течении 1,5 лет, где уже успешно реализован работающий кластер Индустрии 4.0 [3], представляющий собой роботизированный комплекс, включающий прогрессивное металлорежущее оборудование с ЧПУ, обрабатывающие центры, коллаборативные роботы и интерактивные системы и проводятся исследования для осуществления успешного перехода и масштабирования данного кластера с целью достижения такого уровня, который мог бы полноценно отвечать критериям, характерным для производственных систем, описываемых как Индустрия 5.0.

Список литературы

1. Индустрия 5.0: цифровая трансформация с человекоцентричным подходом [Электронный ресурс]. – Режим доступа:

https://journal.ecostandard.ru/ot/kontekst/industriya-5-0-tsifrovaya-transformatsiya-s-chelovekotsentrichnym-podkhodom/ – Дата доступа: 07.10.2026
2. Что такое коллаборативные роботы (коботы)? [Электронный ресурс]. – Режим доступа: https://technored.ru/blog/chto-takoe-kollaborativnye-roboty-koboty – Дата доступа: 07.10.2026
3. Круглый стол «Индустрия 4.0 – ключ к проблемам будущего» состоялся на базе Белорусско-Российского университета [Электронный ресурс]. – Режим доступа: https://fezmogilev.by/services/sobytiya/kruglyy-stol-industriya-4-0-klyuch-k-problemam-budushchego-sostoyalsya-na-baze-belorussko-rossiyskog/ – Дата доступа 07.10.2026

УДК 004.65

ИНТЕГРАЦИЯ ФРЕЙМВОРКА QT И ЯЗЫКА SQL В ПРОЦЕССЕ ПОСТРОЕНИЯ ИНТЕРФЕЙСА АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ УПРАВЛЕНИЯ ПРЕДПРИЯТИЕМ ОВОЩЕВОДСТВА ЗАЩИЩЕННОГО ГРУНТА

Ковтун И.И., канд. техн. наук, доц., ORCID 0009-0005-8222-5290,
Жукова М.А., ORCID 0009-0005-4672-3540,
Мутина М.А., ORCID 0009-0001-3230-6018
ФГБОУ ВО «Московский технический университет связи и информатики»,
г. Москва, РФ
i.i.kovtun@mtuci.ru

Введение. Овощеводство защищенного грунта – одна из наиболее динамично развивающихся отраслей агропромышленного комплекса Российской Федерации, обеспечивающая круглогодичное снабжение населения свежей продукцией [1]. Специфика данной отрасли предполагает непрерывность технологических процессов и детальный учет множества параметров на каждом этапе производственного цикла, что обусловливает необходимость систематического анализа и мониторинга больших объемов разнородных данных, от качества обработки которых зависит эффективность управления предприятием [2], [3].

Для систематизации информации и обеспечения управленческого персонала необходимыми аналитическими инструментами требуется создание специализированного программного обеспечения. Ключевую роль в его функционировании играют средства языка SQL [4], реализующие выполнение сложных выборок и агрегаций данных. Однако их эффективное применение невозможно без предварительного проектирования, учитывающего специфику производственной деятельности предприятий защищенного грунта и структуру обрабатываемой информации. Совокупность обозначенных обстоятельств определила цель проведенного исследования.

Цель – повышение эффективности управления предприятием овощеводства защищенного грунта посредством внедрения специального программного обеспечения, разработанного с помощью фреймворка Qt и языка SQL на основе комплексного анализа реляционной и функциональной модели такого предприятия.

Основная часть. В рамках исследования спроектирована функциональная модель в нотации IDEF0 [5], детализирующая ключевые стадии технологического цикла предприятия овощеводства защищенного грунта. Фрагмент целевого состояния данного процесса TO-BE представлен на рис. 1. Поскольку выполнение указанных операций напрямую связано с накоплением и обработкой оперативных сведений, дополнительно построена реляционная модель [6], структурирующая данные о ресурсах, показателях урожайности, сотрудниках, оборудовании, др. показателях. Соответствующий фрагмент схемы данных представлен на рис. 2.

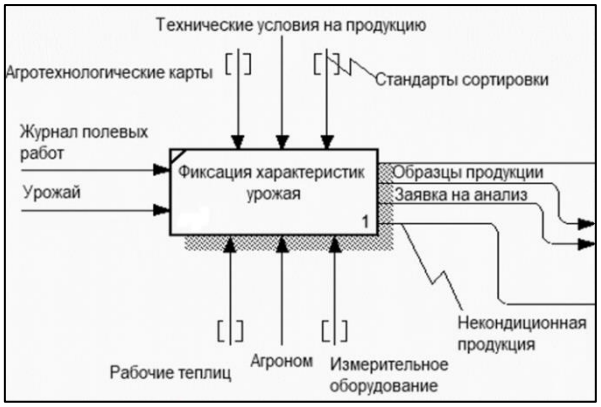


Рис. 1. Фрагмент производственной деятельности тепличного предприятия

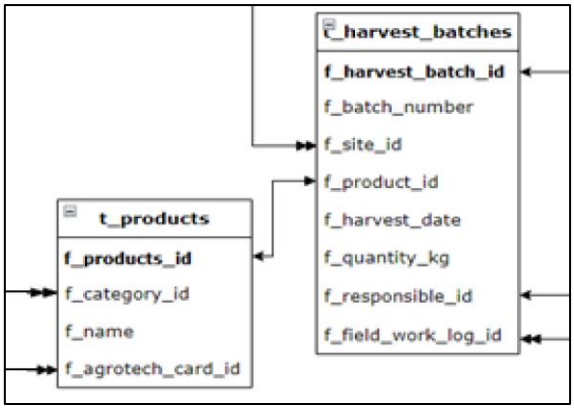


Рис. 2. Фрагмент реляционной модели данных процесса формирования партий

Для обработки данных, структурированных в рамках реляционной модели, применяется язык SQL. С его помощью сформированы таблицы базы данных предприятия и реализованы запросы на выборку информации. В качестве примера в листинге 1 представлены код создания таблицы t_field_work_logs, фиксирующей параметры технологических работы, и формирование запроса на выборку данных о выполненных работах за заданный период с упорядочиванием результатов по дате.

Листинг 1. Фрагмент кода создания таблиц и формирования запросов

```
CREATE TABLE t_field_work_logs(
  f_id integer NOT NULL,
  f_site_id integer,
  f_work_date date NOT NULL,
  f_work_type varchar(200) NOT NULL,
  f_product_id integer,
  f_performed_by integer,
  f_materials_used varchar(300),
  f_notes text,
  f_agrotech_card_id integer );
```

```
SELECT
  f_work_date,
  f_work_type,
  f_materials_used,
  f_notes
FROM t_field_work_logs
WHERE f_work_date
  BETWEEN :from AND :to
ORDER BY f_work_date
```

Практическая реализация программного интерфейса управления предприятием выполнена на языке C++ с применением фреймворка Qt.

Вход в систему осуществляется через форму выбора рабочего места, обеспечивающую аутентификацию и последующее разграничение прав доступа. После успешного входа интерфейс адаптируется под функциональные обязанности сотрудника. Например, автоматизированное рабочее место агронома содержит навигационную панель с модулями ведения агротехнических карт, журнала полевых работ и формирования отчетности. Для оперативного управления данными спроектированы унифицированные формы, включающие инструменты фильтрации по периодам, строки поиска и таблицы с функциями добавления, редактирования и сохранения записей. Особое внимание уделено модулю аналитики, позволяющему генерировать сводные документы и экспортировать их в форматы CSV и PDF. В качестве примера целесообразно привести форму «Отчеты», см. рис. 3.

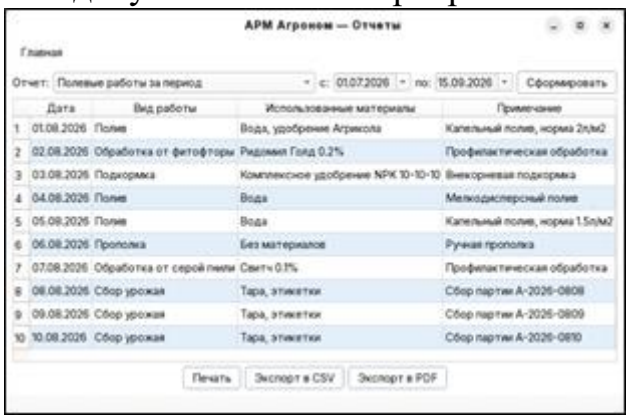


Рис.3 Интерфейс формирования отчета о технологических операциях

Внедрение разработанного программного продукта переводит агрономический учёт в цифровую форму, что снижает трудозатраты на ручной документооборот, обеспечивает непрерывность информационного потока, повышает оперативность контроля качества овощной продукции [7].

Заключение. Результатом исследования является формализация предметной области предприятия овощеводства защищенного грунта и построение информационной структуры, обеспечивающей сквозной учёт партий от теплица до склада. Использование средств языка SQL в рамках разработанного интерфейса обеспечило автоматизацию рутинных операций и повышение оперативности управленческого контроля. Апробация в производственных условиях подтвердила работоспособность предложенных решений и создала основу для комплексной автоматизации предприятий защищенного грунта.

Список литературы

1. Национальный доклад о реализации программы развития сельского хозяйства за 2024 год. URL:https://mcx.gov.ru/press-service/news/predstavlen-natsionalnyy-doklad-o-realizatsii-gosprogrammy-apk-v-2024-godu/.
2. Ковтун И. И. Функционально-реляционный анализ вариантов автоматизации сложных организационно-технических систем. Монография / И. И. Ковтун. – СПб.: Изд-во НИЦ АРТ, 2024. – 214 с.: ил.
3. Караваева Э. А. Применение интеллектуальных инструментов в процессе разработки автоматизированной системы управления информационными потоками и

производственными процессами ткацкой фабрики / Э. А. Караваева, И. И. Ковтун // REDS: Телекоммуникационные устройства и системы. – 2026. – № 1 – С. 17-23.
4. ANSI X.135-1989 «Database Language SQL with Integrity Enhancement».
5. РД 50.1.028-2001. Методология функционального моделирования IDEF0. Руководящий документ. Издание официальное. – М.: ИПК Издательство стандартов, 2000. – 75 с.
6. Мейер Д. Теория реляционных баз данных: Пер. с англ. / Д. Мейер. – М.: Мир, 1987. – 608 с., ил.
7. Ковтун И. И. Интеграция формальных моделей в процессе комплексной автоматизации и интеллектуализации отечественных тепличных производств / И. И. Ковтун, М. А. Жукова, М. А. Мутина // Экономика и управление: проблемы, решения. – 2026. – Т. 7. – № 7. – С. 208–217.

УДК 004.65

ФОРМИРОВАНИЕ ИНФОРМАЦИОННО-АНАЛИТИЧЕСКОЙ ОСНОВЫ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ УПРАВЛЕНИЯ МНОГОНОМЕНКЛАТУРНЫМ ПРОИЗВОДСТВОМ

Ковтун И.И., канд. техн. наук, доц., ORCID 0009-0005-8222-5290,
Малунов Н.Е., ORCID 0009-0005-9920-7662
ФГБОУ ВО «Московский технический университет связи и информатики»,
г. Москва, РФ
i.i.kovtun@mtuci.ru

Введение. Оборонно-промышленный комплекс (ОПК) Российской Федерации остаётся ключевым элементом экономики и национальной безопасности. Тем не менее, согласно [1] доля высокотехнологичной гражданской продукции в отрасли снизилась с 57 % в 1991 г. до 16,8 % в 2016 г. Решение обозначенной проблемы лежит не только в организационной диверсификации, но и технологическом переоснащении жизненного цикла продукции. Значимым фактором, при этом, становится интеграция интеллектуальных систем и аналитических методов в процессы управления и автоматизации многономенклатурных производств [2].

Цель работы – разработка подхода к интеграции аналитических методов в процесс проектирования автоматизированной системы управления многономенклатурным производством, обеспечивающего преодоление ограничений традиционной автоматизации за счёт целостного функционально-реляционного представления производственных процессов, обеспечения адаптивности к изменениям номенклатуры и внешней среды, а также создания механизмов формирования прогнозных аналитических выводов.

Основная часть. Многономенклатурное производство ориентировано на выпуск широкого спектра изделий в рамках единой производст-

венной базы, что позволяет гибко перераспределять загрузку мощностей и снижать зависимость от колебаний спроса. Переход от узкоспециализированного производства с жёсткой номенклатурой к автоматизированному многономенклатурному требует реализации интеллектуальной системы управления, основанной на аналитических методах и формальных математических моделях.

В ходе анализа бизнес-процессов многономенклатурных производств построена функциональная модель по принципу AS-IS в нотации IDEF0 [3] (рис. 1). Далее разработана реляционная модель данных, описывающая предметную область в виде совокупности взаимосвязанных таблиц, аккумулирующих полный диапазон информации, циркулирующей в условиях многономенклатурного производства. Переход от логического уровня к физическому представлен в виде фрагмента обобщённой реляционной модели (рис. 2).

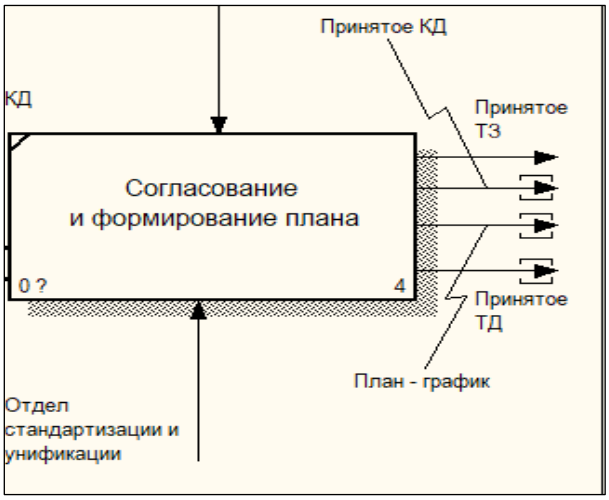


Рис. 1. Фрагмент процесса производственной деятельности по принципу AS IS

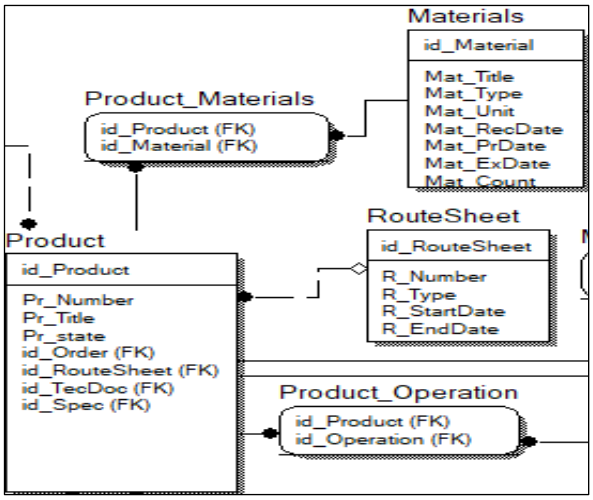


Рис. 2. Фрагмент реляционной модели данных производственного предприятия

Для практической реализации предложенных решений использован язык SQL. Фрагмент кода формирования таблиц представлен в Листинге 1.

Листинг 1. Фрагмент кода формирования таблиц, моделирующих информационные потоки многономенклатурного производства

```
CREATE TABLE Product (
   Id_Product SERIAL PRIMARY KEY, Pr_Number VARCHAR(40)
UNIQUE,
   Pr_Title VARCHAR(30), Pr_State VARCHAR(10), Id_Order INT
   NOT NULL, Id_RouteSheet INT, Id_Tecdoc INT, Id_Spec INT,
   CONSTRAINT fk_product_order FOREIGN KEY
      (Id_Order)REFERENCES "Order"(Id_Order),
   CONSTRAINT fk_product_routesheet FOREIGN KEY
      (Id_RouteSheet) REFERENCES RouteSheet(id_RouteSheet),
   CONSTRAINT fk_product_tecdoc FOREIGN KEY
      (Id_TecDoc) REFERENCES TechnicalDocument(Id_TecDoc),
```

```
   CONSTRAINT fk_product_spec FOREIGN KEY
      (Id_Spec) REFERENCES Specification(Id_Spec));
```

На следующем шаге проведена разработка запросов, реализующих оперативные управленческие решения. Один из запросов представлен в Листинге 2.

Листинг 2. Типовой запрос на языке SQL, реализующий некоторое управленческое решение

```
SELECT
  td.Tec_Name AS документ, td.Tec_version AS версия,
  td.Tec_status AS статус, td.Tec_type AS тип,
  p.Pr_Title AS применяется_в,
  CASE
     WHEN td.Tec_Status = 'Истёк' THEN  'ТРЕБУЕТ ОБНОВЛЕНИЯ'
     WHEN td.Tec_Status = 'На согласовании'  THEN 'В ПРОЦЕССЕ'
     ELSE 'АКТУАЛЬНА'
END
FROM TechnicalDocument td
JOIN Product p ON td.Id_TecDoc = p.Id_TecDoc
ORDER BY td.Tec_Status, td.Tec_Name;
```

В свою очередь, применение функциональных и реляционных моделей в качестве базиса для формирования полного диапазона исходных данных для аналитических методов позволяет сформировать интеллектуальную систему управления, адаптирующуюся к изменениям номенклатуры и спроса. Такое решение, в свою очередь позволяет применить методы оптимизации и машинного обучения [4].

Заключение. По итогам выполненного исследования можно выделить следующие результаты:

– проанализированы существующие бизнес-процессы и информационные потоки многономенклатурного производства;

– разработана логическая и физическая модель данных производственного цикла, а также формализованы типовые запросы, обеспечивающие основу для автоматизированного контроля и интеллектуального анализа.

– спроектирована архитектура единой интеллектуальной платформы, объединяющая функциональные и реляционные модели в целостную информационную среду, которая служит фундаментом для последующей интеграции модулей предиктивной аналитики в технологические процессы различных производств [6], [7].

Список литературы

1. Варшавский А. Е. Повышение показателей эффективности ОПК на основе расширения производства продукции гражданского назначения / А. Е. Варшавский, Ю. А. Макарова // Национальные интересы: приоритеты и безопасность. – 2018. – Т. 14. – № 7. – С. 1199–1219.
2. Скворцов А. А. Применение алгоритмов машинного обучения для прогнозирования отказов и адаптивного управления производственными системами / А. А. Скворцов, М. С. Анурьева, А. Н. Солодовников // Инженерный вестник Дона. – 2025. – №5.

3. Ковтун И. И. Функционально-реляционный анализ вариантов автоматизации сложных организационно-технических систем. Монография / И. И. Ковтун. – СПб.: Изд-во НИЦ АРТ, 2024. – 214 с.: ил.
4. Ефимов, А. И. Основы машинного обучения: учебное пособие / А. И. Ефимов; Южный федеральный университет. – Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2025. – 277 с.
5. Ковтун И. И. Интеграция формальных моделей в процессе комплексной автоматизации и интеллектуализации отечественных тепличных производств / И. И. Ковтун, М. А. Жукова, М. А. Мутина // Экономика и управление: проблемы, решения. – 2026. – Т. 7. – № 7. – С. 208–217.
6. Караваева Э. А. Применение интеллектуальных инструментов в процессе разработки автоматизированной системы управления информационными потоками и производственными процессами ткацкой фабрики / Э. А. Караваева, И. И. Ковтун // REDS: Телекоммуникационные устройства и системы. – 2026. – № 1 – С. 17-23.

УДК 004.9:528.94

РАЗРАБОТКА НАВИГАЦИОННОЙ КАРТЫ ДЛЯ МОБИЛЬНЫХ УСТРОЙСТВ

Козак Л.Я., канд. техн. наук, доц., ORCID 0000-0002-8629-9204,
Строжевский Д.А.
ГОУ ВО «Приднестровский государственный университет им. Т. Г. Шевченко»,
г. Рыбница, ПМР
Ludmilayaroslavovna@gmail.com

Актуальность. Мобильная навигация стала базовой городской инфраструктурой: маршрут до организации, парковка, объезд перекрытий ежедневно строятся на смартфоне, а не на бумажной карте. При этом качество навигационного сервиса определяется не интерфейсом, а актуальностью пространственных данных: организации открываются и закрываются, дорожная сеть меняется вместе со строительством, вводятся временные перекрытия и новые ограничения скорости. Возникает противоречие: темп изменений городской среды в быстрорастущих агломерациях опережает темп обновления картографической основы, и карта устаревает быстрее, чем выходит очередной релиз приложения. Дополнительная проблема носит управленческий характер – при ограниченных ресурсах команды разработки необходимо обоснованно выбирать, какие функции реализуются в первую очередь, тогда как решения нередко принимаются интуитивно, в пользу заметных, но второстепенных возможностей. Это определяет потребность в методике, связывающей функциональный состав навигационного приложения с измеримым вкладом в целевую метрику продукта.

Цель и задачи. Цель работы – обосновать функциональный состав и архитектуру мобильной навигационной карты, обеспечивающей поддер-

жание актуальности пространственных данных и рост числа активных пользователей, на примере городского геоинформационного приложения BaladyPlus. Для достижения цели решались следующие задачи:

1) проанализировать структуру каталога пространственных данных и определить источники и периодичность обновления слоёв (организации, дорожная сеть, здания, ограничения скорости, перекрытия);

2) сформировать функциональный состав приложения и распределить функции по трём измерениям – базовая платформа, работа с данными и функции вовлечения;

3) выполнить количественную приоритизацию функций методом ICE и связать её с целевой метрикой продукта – числом активных пользователей за месяц (MAU);

4) сформировать план реализации на 2027 год и оценить вклад приоритетных функций для привлечения и поддержания пользователей.

Методология. Объектом исследования выступает каталог пространственных данных навигационного приложения, развёрнутый на СУБД PostgreSQL. Каталог организован как последовательность снимков-схем, именуемых по метке времени, каждый снимок содержит порядка 102 таблиц; ключевые таблицы объектов партиционированы по регионам и языкам, что позволяет выпускать обновление по отдельному городу, не пересобирая базу целиком. Медиаданные и картографические тайлы хранятся в S3-совместимом объектном хранилище, мобильный клиент получает данные через сервисный слой. Для приоритизации функций применён метод ICE, при котором каждая функция оценивается экспертно по трём шкалам от 1 до 10 – влияние на целевую метрику (Impact), уверенность в оценке (Confidence) и простота реализации (Ease), – а итоговый балл вычисляется как произведение трёх оценок [1,2]. Выбор ICE обусловлен тем, что он, в отличие от качественных методов (MoSCoW) и более трудоёмких моделей (RICE, требующей оценки охвата в абсолютных величинах), даёт числовой результат при неполных данных на ранней стадии продукта. Дополнительно каждая функция оценивалась по двум прикладным шкалам: «причина выбрать» (потенциал привлечения новых пользователей) и «причина пользоваться» (потенциал поддержания пользователей), что позволяет различать функции, работающие на рост аудитории, и функции, работающие на её сохранение. Порог классификации: высокий приоритет – 350 баллов и выше, средний – от 200 до 349, низкий – менее 200 [3].

Результаты. Сформирован и оценён бэклог из 23 функций, распределённых по трём измерениям: базовая платформа (навигация, карты, парковка) – 6 функций, работа с данными (конвейеры обновления) – 9 функций, функции вовлечения (сообщество, контент, игровые механики) – 8 функций. Итоговые оценки ICE находятся в диапазоне от 60 до 392 баллов при среднем значении 284,4 и медиане 288. К высокому приоритету

отнесены 7 функций (30,4 % бэклога), к среднему – 12 (52,2 %), к низкому – 4 (17,4 %). Наибольшие оценки получили функции, непосредственно связанные с качеством и актуальностью данных: обогащение данных о дорожной обстановке и конвейеры обновления организаций, дорожной сети и временных перекрытий – по 360–378 баллов каждый. Показательно распределение внутри измерений: 4 из 7 функций высшего приоритета относятся к работе с данными, тогда как из шести функций базовой платформы ни одна не вошла в верхнюю группу – работоспособная навигация уже реализована, и дальнейший прирост полезности даёт не интерфейс, а свежесть данных. Наименьшую оценку (60 баллов) получила навигация на смарт-часах и AR-очках: при низкой ожидаемой отдаче она требует наибольших трудозатрат и потому вынесена за пределы горизонта планирования. Сопоставление шкал привлечения и поддержания показало их расхождение: конвейеры обновления данных получили высокие оценки поддержания (8–9 из 10) при низких оценках привлечения (3–5), а игровые и социальные механики – обратное соотношение, что обосновывает необходимость параллельного развития обеих групп, а не последовательного.

Выводы. Проведённое исследование показало, что качество мобильной навигационной карты в первую очередь определяется регулярностью обновления пространственных данных, а не количеством новых функций в интерфейсе. Это подтверждается результатами приоритизации: в группу высокого приоритета вошли четыре функции обновления данных, тогда как ни одна функция базовой платформы в неё не попала. Практическая значимость заключается в сформированном и обоснованном плане развития приложения на 2027 год, применимом в качестве рабочего инструмента планирования, а также в самой методике, сочетающей оценку ICE с раздельными шкалами привлечения и поддержания пользователей. Дальнейшее исследование предполагает верификацию экспертных оценок фактическими продуктовыми метриками после внедрения приоритетных функций и автоматизацию контроля качества данных на стороне конвейеров обновления.

Список литературы

1. Блиновская Я. Ю. Введение в геоинформационные системы: учебное пособие / Я. Ю. Блиновская, Д. С. Задоя. – 2-е изд. – М.: ФОРУМ: ИНФРА-М, 2022. – 112 с.
2. Зольников И. Д. Введение в геоинформационные системы и дистанционное зондирование: учебное пособие / И. Д. Зольников. – М.: Юрайт, 2025. – 118 с.
3. ГОСТ Р 70172-2022. Геодезия и картография. Требования к техническому контролю геодезической и картографической продукции и процессов её создания. Основные положения. – М.: Российский институт стандартизации, 2022. – 16 с.

УДК 004.942

СИМУЛЯТОР РАБОТЫ ВОДОНАГРЕВАТЕЛЬНОЙ СИСТЕМЫ

Колодкин В.М., д-р техн. наук, проф., ORCID 0000-0001-6118-9108,
Акеев А.А.
ФГБОУ ВО «Удмуртский государственный университет», г. Ижевск, РФ
Kolodkin-BM@yandex.ru, mekhaeles@mail.ru

Введение. Водонагревательная система (бойлер) предназначена для нагрева, поддержания температуры и обеспечения запросов Пользователя горячей водой. Система управления бойлером включает управление насосами горячей и холодной воды, устройством нагрева (ТЭНом) и т.д. Система управления обычно строится на основе методологии конечных автоматов. Однако возникают проблемы настройки, если характерные времена процессов нагрева и заполнения водой бойлера значительно (на порядки) различаются. Возникает задача настройки автоматической системы управления, обеспечивающей оптимальный режим функционирования бойлера в широком диапазоне параметров (объем бака бойлера, требуемый температурный диапазон воды, режим отбора горячей воды, мощности нагревателя, насосов и т.д.).

Цель разработать симулятор работы бойлера в широком диапазоне параметров с целью последующего применения его для внедрения нейросетевой модели управления на основе обучения с подкреплением.

Основная часть. Модель нагрева воды в баке бойлера –

$$\frac{d}{dt}(\rho c \cdot V \cdot Q) = P \cdot u - \propto * S * (Q - Q_{sp}) + \rho c \cdot J_{in} \cdot Q_c - \rho c \cdot J_{out} \cdot Q, \quad (1)$$

где Q – температура воды (предполагается полное перемешивание воды в баке бойлера); ρ, c – плотность и теплоемкость воды, V – нагреваемый объем воды в баке бойлера, P – мощность нагревателя, u = 1 – при включении нагревателя и u = 0 – при выключении. Q_{sp}температура окружающей среды, Q_cтемпература холодной воды, $\propto$ – эффективный коэффициент теплообмена воды в бойлере со средой, $J_{in} = J_{cold} \cdot U_{cold}$ – мощность входного потока холодной воды в бойлер; $J_{out} = J_{hot} \cdot U_{hot}$ – мощность выходного потока нагретой воды из бака бойлера, J_{cold}, J_{hot}мощности насосов холодной и горячей воды, U_{cold} , U_{hot}сигналы управления работой насосов холодной и горячей воды, соответственно, Sплощадь поверхности бака.

Модель изменения объема воды V в баке бойлера –

$$\frac{dV}{dt} = J_{in} - J_{out}, \quad (2)$$

Из (1)(2) имеем:

$$\frac{dQ}{dt} = (P \cdot u - \propto \cdot S \cdot (Q - Q_{sp}))/\rho c\, V + J_{in} \cdot (Q_c - Q)/V. \quad (3)$$

Система автоматического управления призвана обеспечить выполнение условий по физическим характеристикам (объем V и температура Q) при отборе горячей воды из бака бойлера. В частности,

$$L_{min} \leq \text{Q} \leq L_{max}\ ,\ F_{min} \leq \text{V} \leq F_{max}$$

где L_{min}, L_{max}пороговые значения температуры воды Q в баке бойлера при отборе горячей воды; F_{min}, F_{max}пороговые значения объема воды в баке бойлера, отвечающие условию отбора горячей воды.

В работе конечного автомата используются логические переменные по температуре

$$T_{low} = \begin{cases} 1, & Q <= L_{min} \\ 0, & \text{иначе} \end{cases}, \qquad T_{high} = \begin{cases} 1, & Q >= L_{max} \\ 0, & \text{иначе} \end{cases}.$$

Аналогично по объему V_{low}, V_{high}. Запрос Пользователя R на горячую воду

$$R = \begin{cases} 1, & \text{при наличии запроса} \\ 0, & \text{иначе} \end{cases}$$

Сигналы управления состоянием бойлера

– Режим работы нагревателя U_H 0, 1 (выкл., вкл);

– Режим работы насоса холодной воды U_CW 0, 1 (выкл., вкл);

– Режим работы насоса горячей воды U_HW 0, 1 (выкл., вкл).

Управляющие сигналы U_H, U_CW и U_HW вырабатываются:

$$U_H = \begin{cases} 0, & Q >= (Q_u - \delta) \\ 1, & Q <= (Q_u + \delta) \end{cases}, \qquad U_{CW} = \begin{cases} 0, & \text{V} >= F_{max} \\ 1, & \text{V} < F_{max} \end{cases},$$

$$\text{U}_\text{HW} = \text{R} \wedge (\neg T_{low}) \wedge (\neg V_{low}).$$

Q_u – температура уставки, δширина зоны гистерезиса по температуре.

Водонагревательная система может находиться в одном из следующих состояний

Состояние (обозначение)	U_HW	U_CW	U_H
Охлаждение (S1)	0, 1	0	0
Наполнение и нагрев (start) (S2)	0, 1	1	1
Наполнение (S3)	0, 1	1	0
Нагрев (S4)	0, 1	0	1

Переходы между состояниями определяются таблицей переходов, построенной с учетом возможных состояний конечного автомата. Например, переход из состояния S2 возможен в состояния: S4, S3 и S1. Условия соответствующих переходов:

S2 --> S4: [(V_{high} = 1) ∧ (U_H = 1)] ;

S2 --> S3: [(T_{high} = 1) ∧ [(V_{low} = 1) V (V_{high} = 0)] ;

S2 --> S1: [(V_{high} = 1) ∧ (U_H = 0)] V [(T_{high}=1) ∧ (V_{high} = 1)].

Последовательность переходов из одного состояния в другое определяется имманентными характеристиками бойлера (объем бака бойлера, мощность нагревательного элемента, мощности насосов горячей и холодной воды, определяющие расходы воды, и т.д.). Вторая важная компонентаэксплуатационные требования к бойлеру (температура нагрева воды в баке бойлера, допустимые колебания температуры и объема изымаемой горячей воды и т.д.).

Симулятор построен в рамках среды динамического моделирования технических систем SimInTech. Использован инструментарий библиотеки «Конечные автоматы» [1].

Для иллюстрации работы симулятора представлены графики изменения температуры и объема воды в бойлере, полученных в рамках SimInTech, при одном из наборов характеристик бойлера.



Рис. Результаты моделирования водоподготовки воды

Заключение. Результаты моделирования функционирования бойлера в рамках симулятора способны обеспечить внедрение нейронной сети.

Список литературы

1. Библиотека блоков «Конечные автоматы» // Справочный центр SimInTech [Электронный ресурс]. – URL: https://help.simintech.ru/10_biblioteki_blokov/DIR_konechnye_avtomaty.html (дата обращения: 07.10.2026).

УДК 004.8

ВЛИЯНИЕ МУЛЬТИМОДАЛЬНЫХ ДАННЫХ ЭКРАНА И ВЗГЛЯДА НА РАСПОЗНАВАНИЕ РАБОЧИХ РЕЖИМОВ

Коротеев С.С.
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
dhonehi@yandex.ru

Введение. Нажатия клавиш и клики мыши показывают активность за компьютером, но по ним трудно отличить рабочую задачу от отвлечения [1]. Характеристики нажатий также применяют для анализа поведения пользователя [4]. Дополнительные сведения дают используемые приложения и направление взгляда. Совместное использование таких источников называют мультимодальным подходом [2, 3].

Цель работы. Сравнить семь моделей распознавания рабочих режимов по показателям работы с клавиатурой и мышью, данными экрана и взгляда. Определить, какие модели и сочетания данных дают лучший результат.

Данные. Набор содержит 50 000 пятиминутных записей десяти профилей сотрудников: девяти разработчиков и одного тестировщика. Записи объединены в 622 сессии и датированы мартом–маем 2026 года. Доли глубокой работы, рутинной работы, поиска информации, отвлечения и перерыва составляют 43,4 %; 27,6 %; 13,1 %; 3,6 % и 12,3 % соответственно. Модели обучались по готовым меткам этих режимов.

Использованы 22 признака трёх групп. Под действиями пользователя понимаются семь показателей: число нажатий клавиш, кликов мышью и переключений активного окна, время движения мыши и бездействия, число нажатий и кликов за минуту активности. Эти показатели описывают, как сотрудник работает с клавиатурой, мышью и окнами приложений.

Данные экрана включают восемь показателей: доли использования категорий приложений, общую долю рабочих приложений и наибольшую долю одной категории. Семь показателей взгляда описывают доступность камеры, долю взгляда на экран, число и долю распознанных проверок, количество и длительность отвлечений. Камера доступна в 87,2 % записей. За пять минут предусмотрено 30 проверок взгляда с шагом 10 секунд.

Экспериментальная проверка. Было произведено сравнение четырех наборов признаков: показатели действий пользователя, их сочетание с данными экрана, их сочетание с показателями взгляда и все три группы вместе. Обучены логистическая регрессия, Random Forest [6], Extra Trees [5], MLP, LSTM [7] и Transformer [2]. Седьмой вариант объединяет вероятности отдельных логистических моделей для каждой группы данных.

Проверка включает десять этапов. На каждом этапе один сотрудник полностью исключается из обучения и используется для проверки. Из

остальных девяти два служат для выбора настроек, семь – для обучения. После выбора модель заново обучается на всех девяти. Проверочные данные не участвуют в настройке. Идентификатор сотрудника, роль и время не используются как признаки.

Все модели получают текущий интервал и до пяти предыдущих в той же сессии. Пропуски заполняются медианами, признаки приводятся к общей шкале по обучающей части. Недостающая история заполняется нулями и отмечается маской. Табличные модели получают историю одной строкой, LSTM и Transformer – последовательностью. Для редких классов используются повышенные веса.

Лесные модели содержат по 120 деревьев. Для регрессии проверены значения C 0,03; 0,3 и 3, для лесов – минимальный размер листа 2 или 8. MLP имеет слои из 64 и 32 нейронов, LSTM – 32 скрытых элемента. Transformer содержит один блок, четыре головы внимания и размерность 32. Сети обучаются методом Adam с шагом 0,002 или 0,0007, пакетами по 2048 записей, не более 20 эпох. Для всех наборов признаков используются одинаковые варианты настроек. Настройки, число эпох и веса источников при объединении выбираются по macro F1 на двух сотрудниках из обучающей части.

Результаты. Основной показатель – macro F1: каждый из пяти режимов имеет одинаковый вес. В таблице приведено среднее по десяти проверочным сотрудникам. Accuracy показывает общую долю верных прогнозов.

Таблица

Средний macro F1 для разных источников данных

Модель	**Д**	**Д + Э**	**Д + В**	**Д + Э + В**
Логистическая регрессия	0,543	0,647	0,540	0,647
Random Forest	0,543	0,669	0,540	0,663
Extra Trees	0,543	0,667	0,542	0,663
MLP	0,541	0,677	0,543	0,676
Объединение оценок	0,543	0,645	0,542	0,645
LSTM	0,540	0,682	0,541	0,681
Transformer	0,544	0,680	0,547	0,675

Д – показатели действий пользователя; Д + Э – показатели действий и данные экрана; Д + В – показатели действий и взгляда; Д + Э + В – все три группы данных.

У всех семи моделей набор всех трёх источников превзошёл одни действия на каждом из десяти проверяемых профилей. Лучший средний macro F1 получила LSTM при использовании действий и экрана: 0,682. У LSTM со всеми признаками macro F1 составил 0,681 против 0,540 при

использовании только действий. Прирост равен 0,141. Наибольшая Accuracy составила 73,1 % у LSTM при использовании действий и экрана.

У LSTM добавление показателей взгляда к показателям действий и данным экрана изменило macro F1 с 0,6822 до 0,6807. На этом наборе данных результат модели почти не изменился.

По всем проверочным прогнозам LSTM со всеми признаками лучше всего распознавала режим перерыва (F1 = 0,828). Самым сложным было распознавание отвлечения (F1 = 0,492). Короткие отвлечения могут пропускаться при проверке взгляда раз в 10 секунд. Выборка ограничена десятью профилями, преимущественно разработчиков.

Заключение. Добавление данных экрана повысило качество распознавания по сравнению с использованием только показателей действий пользователя. Лучший результат продемонстрировала LSTM при использовании действий и экрана (macro F1 = 0,682). В этом эксперименте добавление показателей взгляда не улучшило её результат.

Список литературы

1. Kalischko, T. Electronic Performance Monitoring in the Digital Workplace: Conceptualization, Review of Effects and Moderators, and Future Research Opportunities / T. Kalischko, R. Riedl. // Frontiers in Psychology. – 2021. – Vol. 12. – Art. 633031. – URL: https://doi.org/10.3389/fpsyg.2021.633031 (дата обращения: 01.10.2026). – Дата публикации: 21.05.2021. – DOI 10.3389/fpsyg.2021.633031
2. Xu, P. Multimodal Learning With Transformers : A Survey / P. Xu, X. Zhu, D. A. Clifton. // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2023. – Vol. 45, no. 10. – P. 12113–12132. – DOI 10.1109/TPAMI.2023.3275156
3. Карпов, А. А. Многомодальные интерфейсы человеко-машинного взаимодействия / А. А. Карпов, Р. М. Юсупов // Вестник Российской академии наук. – 2018. – Т. 88, № 2. – С. 146–155. – DOI 10.7868/S0869587318020056
4. Кочегурова, Е. А. Скрытый мониторинг пользователя в дистанционной образовательной системе на основе клавиатурной динамики / Е. А. Кочегурова, Р. П. Затеев // Программирование. – 2022. – № 6. – С. 31–45. – DOI 10.31857/S0132347422060048
5. Geurts, P. Extremely randomized trees / P. Geurts, D. Ernst, L. Wehenkel // Machine Learning. – 2006. – Vol. 63. – P. 3–42. . – DOI 10.1007/s10994-006-6226-1
6. Breiman, L. Random Forests / L. Breiman. // Machine Learning. – 2001. – Vol. 45. – P. 5–32. – DOI 10.1023/A:1010933404324
7. Goodfellow, I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge, MA: MIT Press, 2016. – 800 p. – ISBN 978-0-262-03561-3.

УДК 004.75

ДЕЦЕНТРАЛИЗОВАННОЕ РАСПРЕДЕЛЕНИЕ ВЫЧИСЛИТЕЛЬНЫХ ЗАДАНИЙ В ЛОКАЛЬНОЙ СЕТИ ДЛЯ КВАНТОВО-ХИМИЧЕСКИХ РАСЧЁТОВ

Котенко В.Н., ORCID 0009-0006-3867-1645,
Коваль Г.Д., ORCID 0009-0005-2811-2703
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
kotenko1967@mail.ru, koval.gk@yandex.ru

Введение. Программный комплекс ORCA применяется для квантово-химического моделирования молекулярных систем [1]. Серии независимых расчётов можно выполнять одновременно на компьютерах локальной сети. Однако ручное распределение требует учитывать занятость машин, переносить файлы, контролировать выполнение и собирать результаты. При недоступности исполнителя необходимо повторно назначать задания. Автоматизация этих операций упрощает управление очередью и использование вычислительных ресурсов.

Целью работы является разработка системы, которая объединяет компьютеры локальной сети для автоматического распределения заданий программного комплекса ORCA, контролирует их выполнение и предоставляет пользователю единый способ доступа к состоянию расчётов и выходным файлам.

Основная часть. Разработанная система построена по децентрализованному принципу. Каждый компьютер является равноправным узлом и может принимать задания от пользователя, выполнять расчёты и предоставлять сведения обо всей очереди. Постоянный управляющий сервер не требуется. Узлы обнаруживают друг друга с помощью широковещательных сообщений UDP. При подключении узел сообщает свой идентификатор, число процессорных ядер, объём оперативной памяти и количество доступных мест для выполнения заданий. Периодические сообщения позволяют другим участникам отслеживать его доступность и текущую загрузку.

В ORCA параметры расчёта задаются во входном файле с расширением .inp [2]. В разработанной системе один такой файл соответствует одному заданию в очереди. После отправки файла через веб-интерфейс, командную строку или HTTP API принимающий узел сохраняет его локально и распространяет сообщение о новом задании. Обмен сообщениями между равноправными узлами применяется в распределённых системах для распространения изменений между локальными копиями данных [3]. Сведения о создании задания, выборе исполнителя, начале и завершении расчёта передаются между узлами в виде отдельных событий. Узел применяет полученные события к локальной таблице заданий,

поэтому состояние очереди доступно без обращения к центральному серверу. Для разрешения конкурирующих изменений используются метка времени и идентификатор отправившего узла. Повторное получение события не меняет принятое состояние задания: расчёт запускает узел, выбранный его исполнителем.

Планировщик каждого узла проверяет наличие свободных мест для выполнения расчётов. Их количество определяется исходя из числа процессорных ядер компьютера и заданного числа процессов ORCA на одно задание. Из ожидающих заданий выбираются подходящие по доступным ресурсам; учитываются время поступления и установленный приоритет. При подаче задания пользователь также может указать обязательный или предпочтительный узел и требования к числу ядер и объёму памяти. Это позволяет сочетать автоматическое распределение с ручным выбором исполнителя для отдельных расчётов.

Для согласования выбора исполнителя свободный узел рассылает сообщение о намерении принять задание в работу и одновременно учитывает собственную заявку в локальной таблице. Затем планировщик выдерживает короткий интервал, в течение которого могут поступить заявки других узлов. При конкуренции заявок преимущество определяется сравнением времени их создания и идентификаторов узлов. По окончании интервала каждый кандидат проверяет, кому принадлежит задание согласно известному ему состоянию таблицы. Узел, выигравший выбор, получает входной файл и запускает ORCA, а остальные прекращают попытку выполнения этого задания. ORCA допускает запуск параллельных процессов посредством MPI [4]. В разработанной системе процессы одного расчёта запускаются на одном компьютере, а между компьютерами распределяются отдельные задания.

Общий сетевой диск не требуется: исполнитель получает входной файл по HTTP от узла, принявшего задание. Для каждого расчёта создаётся отдельный каталог с исходными данными, журналом и результатами. Выходные файлы остаются у исполнителя. Другие узлы передают ему запросы пользователя и возвращают полученные данные, обеспечивая доступ к результатам через любой подключённый компьютер.

Выполнение контролируется механизмом ограниченного срока владения заданием. Работающий узел периодически продлевает этот срок. Если продление прекращается, задание возвращается в состояние ожидания и становится доступным для повторного назначения. При временной недоступности компьютера с исходным файлом попытка передачи откладывается. При повторном запуске удаляются промежуточные файлы предыдущей попытки, которые могли бы повлиять на новый расчёт. После завершения процесса дополнительно проверяется наличие в выходном файле сообщения ORCA о нормальном окончании: одного нулевого кода завершения процесса недостаточно для подтверждения успешного расчёта.

Для развёртывания используется Docker-образ, объединяющий программу и её зависимости [5]. Он включает Python 3.12, ORCA 6.1.1 и OpenMPI 4.1.6. При сборке архив ORCA восстанавливается из частей и проверяется по SHA-256. Отдельная установка ORCA и OpenMPI на компьютерах не требуется. Программная часть использует стандартную библиотеку Python. Контейнерам необходим доступ к широковещательным сообщениям UDP и HTTP API соседних узлов.

Встроенный веб-интерфейс отображает доступные компьютеры, очередь и состояния заданий. Через него можно отправить входной файл, просмотреть журнал и выходные файлы, отменить расчёт либо повторно поставить задание в очередь. Те же основные операции доступны через интерфейс командной строки. Для проверки подлинности сообщений между узлами применяется механизм HMAC, основанный на общем секретном ключе [6]. В реализованной системе сообщения снабжаются подписью HMAC-SHA256, а обращения к HTTP API при включённой аутентификации требуют передачи токена. Этот механизм позволяет проверять подлинность запросов и сообщений внутри локальной сети.

Заключение. Разработана децентрализованная система для организации серии расчётов ORCA на компьютерах локальной сети. Реализованы автоматическое обнаружение узлов, согласование состояния очереди, выбор исполнителя с учётом ресурсов, передача входных файлов без общего хранилища, запуск и контроль расчётов, а также доступ к выходным файлам через любой узел. Контейнеризация упрощает развёртывание одинаковой программной среды на компьютерах, участвующих в выполнении заданий.

Список литературы

1. Neese F. Software Update: The ORCA Program System – Version 6.0 / F. Neese // WIREs Computational Molecular Science. – 2025. – Vol. 15, № 2. – Article e70019. DOI: 10.1002/wcms.70019.
2. Running ORCA // ORCA 6.1.1 Manual. URL: https://orca-manual.mpi-muelheim.mpg.de/contents/quickstartguide/running.html (дата обращения: 10.09.2026).
3. Demers A. Epidemic Algorithms for Replicated Database Maintenance / A. Demers et al. // Proceedings of the Sixth Annual ACM Symposium on Principles of Distributed Computing. – 1987. – P. 1–12. DOI: 10.1145/41840.41841.
4. Parallel and Multi-Process Runs // ORCA 6.1.1 Manual. URL: https://orca-manual.mpi-muelheim.mpg.de/contents/essentialelements/parallel.html (дата обращения: 10.09.2026).
5. What is Docker? // Docker Docs. URL: https://docs.docker.com/get-started/docker-overview/ (дата обращения: 11.09.2026).
6. Krawczyk H., Bellare M., Canetti R. HMAC: Keyed-Hashing for Message Authentication. – RFC 2104. – 1997. URL: https://datatracker.ietf.org/doc/html/rfc2104 (дата обращения: 25.09.2026).

УДК 004.415.2

ПРОЕКТИРОВАНИЕ И РАЗРАБОТКА WEB-ОРИЕНТИРОВАННОЙ СИСТЕМЫ УЧЁТА И ОБРАБОТКИ ДАННЫХ АБИТУРИЕНТОВ

Котенко В.Н., ORCID 0009-0006-3867-1645,
Королёв А.В., ORCID 0009-0003-7235-203X
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
kotenko1967@mail.ru, badron.korol@mail.ru

Введение. Каждый год приёмные комиссии вузов обрабатывают большие потоки информации о поступающих, и от того, насколько грамотно организован этот процесс, напрямую зависит качество набора и скорость подготовки итоговых отчётов. Среди типичных недостатков используемых сегодня решений можно назвать перегруженный интерфейс, наличие избыточных функций, слабую адаптацию под конкретные учебные заведения и отсутствие полноценной аналитики. На многих кафедрах данные абитуриентов до сих пор ведутся в обычных таблицах Excel, что заметно повышает риск ошибок и тормозит работу сотрудников.

Приёмная кампания, будучи критически важным процессом взаимодействия между вузом и абитуриентами, требует высокой операционной эффективности, прозрачности и качества сервиса. Традиционные модели, основанные на бумажном документообороте и ручных операциях, становятся источником ряда системных проблем: высокой нагрузки на персонал, рисков человеческих ошибок, временных задержек и ограниченной доступности информации для поступающих [1].

Актуальность темы объясняется ростом числа поступающих в высшие учебные заведения: кафедрам ежегодно приходится работать со значительными объёмами информации приёмной кампании, а значит, требуются удобные и надёжные инструменты для её обработки и анализа.

Существующие коммерческие решения часто характеризуются высокой стоимостью и сложностью адаптации под специфические потребности отдельных кафедр. Разработка специализированного приложения (автоматизированная система управления, АСУ) позволяет создать инструмент, максимально адаптированный под конкретные задачи образовательного учреждения, с возможностью дальнейшего развития и модификации функциональности [2].

Целью данной работы стало проектирование и разработка веб-приложения на языке программирования Python для учёта и обработки данных абитуриентов кафедры, которое обеспечит надёжное хранение информации, автоматизацию составления рейтинговых списков и отчётов, а также инструменты для анализа и визуализации данных о поступающих с доступом с любого устройства через обычный браузер.

Основная часть. В ходе исследования была спроектирована и реализована система учёта абитуриентов, построенная вокруг единой базы данных MySQL и серверной части на фреймворке FastAPI.

Одной из ключевых особенностей выбранного подхода стала архитектура «одна база данных, разные способы доступа». В отличие от классического настольного приложения, привязанного к конкретной операционной системе, веб-ориентированное решение позволяет нескольким сотрудникам приёмной комиссии одновременно работать с одной и той же базой данных через браузер, независимо от того, установлена ли на их компьютере Windows, Linux или macOS. При необходимости к той же базе данных в будущем можно подключить и отдельное настольное приложение, поскольку серверная часть отделена от способа отображения данных и взаимодействует с клиентом через стандартный программный интерфейс. Это существенно повышает гибкость системы и снижает затраты на её сопровождение.

Архитектура приложения включает следующие компоненты: модель данных, реализованная в виде связанных таблиц базы данных (абитуриент, заявление, учебное заведение, город и регион, родитель, льготы, результаты экзаменов); серверные маршруты, отвечающие за стандартизированный доступ к данным через REST API; реестр абитуриентов, обеспечивающий централизованное хранение списка поступающих с возможностью поиска, сортировки и фильтрации записей; клиентский веб-интерфейс, включающий главную страницу с таблицей абитуриентов (рис. 1), формы добавления и редактирования записей (рис. 2), а также отдельные разделы для аналитики и журнала изменений.

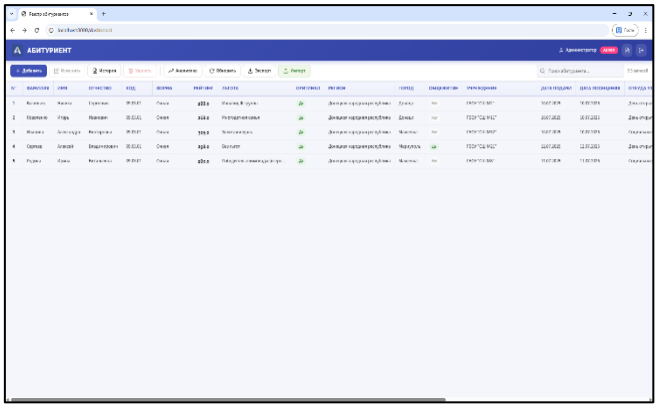


Рис. 1. Главная страница web-приложения

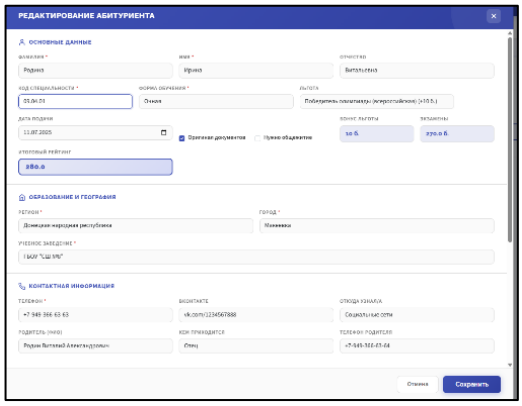


Рис. 2. Форма добавления и редактирования записи

Особое внимание при разработке было уделено скорости поиска и фильтрации данных, чтобы сотрудник мог быстро находить нужную запись при работе с крупной базой: реализован поиск по фамилии, региону, городу, учебному заведению, а также фильтрация по наличию льгот и оригиналов документов. Техническая реализация системы

обеспечивает простой интерфейс, доступный с компьютера, ноутбука или планшета без установки дополнительного программного обеспечения; стабильную работу при базе данных из нескольких сотен и более записей за счёт асинхронной обработки запросов на сервере; защиту персональных данных абитуриентов посредством ролевого разграничения доступа и аутентификации по токенам; развёртывание всей системы одной командой с помощью контейнеризации, без ручной настройки базы данных на каждом сервере.

Отдельный журнал аудита фиксирует все операции с данными, включая указание конкретного изменённого поля, старого и нового значения, что обеспечивает прозрачность работы сотрудников и возможность проверки действий при необходимости.

Заключение. Разработанная веб-система учёта и обработки данных абитуриентов заметно облегчает работу сотрудников приёмной комиссии, уменьшает вероятность ошибок при вводе информации и ускоряет подготовку итоговой отчётности. Переход от настольного приложения к веб-ориентированному решению с единой базой данных даёт дополнительное преимущество: одна и та же информация становится доступной с разных устройств и, при дальнейшем развитии проекта, из разных клиентских приложений, будь то браузер или отдельная программа, без риска расхождения данных между ними. Применение современных технологий, в том числе элементов интеллектуальных ассистентов [3], наряду с объектно-ориентированным подходом к проектированию серверной логики, позволяет описывать сущности предметной области последовательно и логично, приближая модель системы к реальным процессам приёмной кампании.

Благодаря разработанной системе удалось проанализировать географию абитуриентов кафедры компьютерных технологий ДонГУ за пятилетний период. Выявление основных «поставщиков» студентов среди школ, техникумов и городов Донецкого региона позволит сделать набор на кафедру более точным и результативным.

Список литературы

1. Кирпичѐва Е. Ю. Автоматизация приемной кампании вуза в условиях многозадачного подхода / Е. Ю. Кирпичѐва, Т. О. Махалкина, Е. А. Русакова // Системный анализ в науке и образовании: сетевое научное издание. – 2023. – №3. – С. 26-37. EDN: REQFYU. URL: https://sanse.ru/index.php/sanse/article/view/586.
2. Мезенцев К. Н. Автоматизированные информационные системы : учебник для студ. учреждений сред. проф. образования / К. Н. Мезенцев. – 4-е изд., стер. – М.: Издательский центр «Академия», 2013. – 176 с. ISBN 978-5-7695-9885-2
3. Котенко В. Н. Метод повышения эффективности учета научной деятельности кафедры высшего учебного заведения / В. Н. Котенко // Донецкие чтения 2018: образование, наука, инновации, культура и вызовы современности: материалы III Международной научной конференции, Донецк, 25 октября 2018 года. – Донецк: Донецкий национальный университет, 2018. – С. 127-130. – EDN MHNEKD.

УДК 004.42:614.2

АВТОМАТИЗАЦИЯ УПРАВЛЕНИЯ ПЕРСОНАЛОМ И БИЗНЕС-ПРОЦЕССАМИ МЕДИЦИНСКОЙ КЛИНИКИ НА ОСНОВЕ ВЕБ-ОРИЕНТИРОВАННОЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ

Котенко Ю.В., ORCID 0009-0008-4281-2572,
Гузенко В.С., ORCID 0009-0003-9357-8046
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
melin1989@mail.ru; *guzenkovalentin2006@mail.ru*

Аннотация. В статье рассматривается автоматизация процессов управления персоналом медицинской клиники с использованием разработанного веб-приложения. Рассмотрены процессы работы с данными о сотрудниках, должностях, подразделениях и расписаниях. Описан переход от разрозненной обработки информации к централизованному хранению и разграничению доступа пользователей. Определена отличительная особенность разработанного решения, заключающаяся в объединении кадровой информации с расписанием и связанными организационными процессами.

Ключевые слова: автоматизация, управление персоналом, медицинская клиника, веб-приложение, информационная система, расписание, разграничение доступа.

Введение. Деятельность медицинской клиники связана с обработкой информации о сотрудниках, должностях, подразделениях, графиках работы и пациентах. При использовании разрозненных способов хранения данных увеличивается количество ручных операций и усложняется получение актуальной информации.

Для автоматизации деятельности медицинских организаций применяются специализированные информационные системы. Например, решения «1С:Медицина» предусматривают работу с персоналом и графиками сотрудников [1, 2], а медицинские информационные системы объединяют работу с расписанием, пациентами и медицинской документацией [3].

Целью работы является автоматизация процессов управления персоналом медицинской клиники на основе разработанного веб-приложения.

На этапе проектирования был проведён анализ предметной области и определены основные процессы управления персоналом: хранение сведений о сотрудниках, должностях и подразделениях, формирование расписаний, управление пользователями и разграничение доступа.

Для анализа процессов были разработаны модели «КАК ЕСТЬ» и «КАК ДОЛЖНО БЫТЬ». В исходном варианте значительная часть операций выполняется сотрудниками вручную. В автоматизированном варианте информационная система участвует в хранении, обработке и предоставлении данных.

Центральным объектом приложения является персонал медицинской клиники. Сведения о сотрудниках связаны с должностями, подразделениями и рабочим расписанием. Централизованное хранение позволяет использовать одни и те же данные при выполнении различных операций без повторного ввода информации.

Одним из направлений автоматизации является управление расписанием. Информация о сотрудниках используется при формировании графиков работы и организации записи пациентов. Таким образом, кадровые сведения связываются с рабочим временем специалистов и другими процессами клиники.

В приложении предусмотрено разграничение доступа пользователей по ролям. Выделены администратор, регистратор, врач и медицинский персонал. Администратор управляет сотрудниками, пользователями, расписаниями и правами доступа. Регистратор работает с пациентами и записью на приём. Врач получает доступ к медицинской информации и отчётности, а медицинский персонал – к функциям, связанным с процедурами и результатами анализов.

Ролевая модель позволяет учитывать организационную структуру клиники и предоставлять пользователям только необходимые функции. При этом кадровая информация используется не изолированно, а связывается с другими объектами системы.

Приложение разработано с использованием PHP и фреймворка Laravel, а для хранения данных используется MySQL. Взаимодействие с серверной частью организовано через REST API. Для документирования и тестирования API применяется Swagger [4, 5].

Отличительной особенностью разработанного решения является ориентация не только на хранение кадровых сведений, но и на их использование в связанных организационных процессах. Информация о сотрудниках объединяется с данными о должностях, подразделениях, расписаниях и ролях пользователей в едином информационном пространстве.

Результаты. В результате разработано веб-приложение для автоматизации процессов управления персоналом медицинской клиники. Реализовано централизованное хранение и обработка информации о сотрудниках и связанных объектах.

Применение ролевой модели позволяет распределить функции между различными категориями пользователей. Связь кадровых данных с расписанием обеспечивает использование информации о сотрудниках при организации их рабочего времени и связанных процессов.

Использование REST API и Swagger обеспечивает взаимодействие с серверной частью и возможность проверки реализованных операций. Разработанная архитектура допускает дальнейшее расширение функциональности приложения.

Практическая значимость разработанного приложения заключается в возможности использования единого источника актуальной информации

при выполнении повседневных операций. При изменении сведений о сотруднике, его должности или рабочем расписании соответствующие данные могут использоваться в связанных процессах системы. Это позволяет уменьшить дублирование информации и упростить взаимодействие между различными категориями пользователей.

Применение ролевого доступа дополнительно обеспечивает соответствие доступных функций должностным обязанностям сотрудников клиники.

В работе рассмотрена автоматизация процессов управления персоналом медицинской клиники. На основе анализа предметной области определены основные операции, связанные с обработкой сведений о сотрудниках, расписаниях и пользователях.

Разработанное приложение объединяет кадровую информацию и связанные организационные процессы в едином информационном пространстве. Отличительной особенностью решения является использование данных о персонале не только для кадрового учёта, но и при формировании расписаний, организации доступа пользователей и выполнении связанных операций.

Разработанное приложение при необходимости легко может быть расширено дополнительными функциями по управлению персоналом, отчётностью и интеграцией с другими информационными системами клиники.

Список литературы

1. Балдин, К. В. Информационные системы в экономике: учебник / К. В. Балдин, В. Б. Уткин. – 8-е изд. – Москва: Дашков и К, 2019. – 395 с. – ISBN 978-5-394-03244-8.
2. Инюшкина, О. Г. Проектирование информационных систем (на примере методов структурного системного анализа): учебное пособие / О. Г. Инюшкина. – Екатеринбург: Форт-Диалог Исеть, 2014. – 240 с. – ISBN 978-5-91128-072-7.
3. Арлоу, Д. UML 2 и Унифицированный процесс. Практический объектно-ориентированный анализ и проектирование / Д. Арлоу, И. Нейштадт; пер. с англ. – 2-е изд. – Санкт-Петербург: Символ-Плюс, 2007. – 624 с. – ISBN 978-5-93286-094-6.
4. 1С:Медицина. Поликлиника: возможности решения. – Текст: электронный // Фирма «1С»: официальный сайт. – 2020. – URL: https://solutions.1c.ru/catalog/clinic (дата обращения: 29.09.2026).
5. 1С:Медицина. Стоматологическая клиника: возможности решения. – Текст: электронный // Фирма «1С»: официальный сайт. – 2023. – URL: https://solutions.1c.ru/catalog/stoma/features (дата обращения: 29.09.2026).

УДК 004.77:004.415

ПРОЕКТИРОВАНИЕ УНИВЕРСАЛЬНОЙ ВЕБ-ПЛАТФОРМЫ ОНЛАЙН-ЗАПИСИ И УПРАВЛЕНИЯ УСЛУГАМИ С ПРЕДМЕТНО-ОРИЕНТИРОВАННОЙ КОНФИГУРАЦИЕЙ

Котенко Ю.В., ORCID 0009-0008-4281-2572,
Кривенчук А.Ю., ORCID 0009-0003-8655-031X
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
melin1989@mail.ru; krivenchuck@vk.com

Введение. Цифровая трансформация сферы услуг обусловливает возрастающую потребность в автоматизации процессов взаимодействия организаций с клиентами. Существующие коммерческие SaaS-платформы онлайн-записи (Yclients, Dikidi, Sonline) предоставляют инструменты управления расписанием и бронированием, однако обладают рядом существенных ограничений: избыточная функциональность, не востребованная малым бизнесом; высокая стоимость подписки; слабая адаптируемость под специфику конкретной организации [1]. Параллельно возрастает роль мессенджеров как приоритетного канала коммуникации: интеграция с Telegram существенно повышает конверсию бронирования по сравнению с традиционными веб-формами, поскольку пользователи предпочитают совершать действия внутри привычных приложений [2]. Указанные факторы формируют запрос на проектирование архитектуры открытой веб-платформы, обеспечивающей адаптацию к произвольной предметной области средствами конфигурирования, а не модификации исходного кода.

Цель работы состоит в проектировании и реализации универсальной веб-платформы онлайн-записи и управления услугами, допускающей предметно-ориентированную конфигурацию каталога услуг, ролевой модели, бизнес-правил и каналов уведомления без изменения программного ядра. Платформа объединяет веб-интерфейс для сотрудников организации и Telegram-бота для клиентов в единой информационной среде.

Архитектура платформы. Система построена по трёхзвенной клиент-серверной архитектуре, в которой выделены презентационный слой, слой бизнес-логики и слой данных [3]. Презентационный слой включает два независимых клиентских модуля: адаптивный веб-интерфейс (JavaScript, TailwindCSS) для мастеров и администраторов и Telegram-бота для клиентов. Оба модуля обращаются к единому серверному ядру, что исключает рассинхронизацию расписания при одновременном бронировании через разные каналы. Слой бизнес-логики реализован на PHP с применением фреймворка Laravel, обеспечивающего маршрутизацию запросов, валидацию входных данных, аутентификацию и

авторизацию, систему очередей для асинхронной отправки уведомлений и планировщик задач для автоматического изменения статусов записей [4]. Слой данных представлен СУБД MySQL 8.0 с механизмом хранения InnoDB, поддержкой ACID-транзакций, индексацией по полям поиска и кодировкой utf8mb4. Взаимодействие приложения с базой данных осуществляется через объектно-реляционное отображение Eloquent ORM. Telegram-бот функционирует через официальный Telegram Bot API посредством механизма webhook, обеспечивая интерактивное пошаговое бронирование с использованием inline-клавиатуры.

Модель данных. Концептуальная модель предметной области включает пять базовых сущностей: РОЛИ, ПОЛЬЗОВАТЕЛИ, УСЛУГИ, СТАТУСЫ_ЗАПИСЕЙ, ЗАПИСИ. Все межтабличные связи реализованы по принципу «один-ко-многим» (1:N). Центральной сущностью является ЗАПИСИ, аккумулирующая внешние ключи на пользователя-клиента, пользователя-мастера, услугу и текущий статус. Нормализация до третьей нормальной формы исключает избыточность и обеспечивает ссылочную целостность данных. Физическая реализация использует составные индексы по полям `master_id`, `start_at` и `status_id` для эффективной проверки конфликтов временных слотов при бронировании.

Предметно-ориентированная конфигурация. Ключевой архитектурной особенностью платформы является механизм предметно-ориентированной конфигурации, позволяющий адаптировать систему к различным отраслям сферы услуг (салоны красоты, медицинские кабинеты, автосервисы, фитнес-студии) средствами административного интерфейса без модификации программного кода. Конфигурируемыми элементами выступают: каталог услуг с указанием наименования, стоимости и длительности; графики работы организации и индивидуальные расписания специалистов; справочник статусов записей с настраиваемой цветовой индикацией и логикой переходов между состояниями; параметры временных слотов (шаг записи, буферное время между клиентами); шаблоны уведомлений и каналы их доставки (Email, Telegram). Данный подход реализует принцип разделения программного ядра и предметной модели: бизнес-правила параметризуются через справочные таблицы базы данных, что сокращает стоимость внедрения и снижает порог вхождения для администраторов без технической подготовки.

Программная реализация. Ролевая модель системы предусматривает три уровня доступа. Клиент взаимодействует с платформой через Telegram-бота, проходя пошаговый сценарий бронирования: выбор услуги, специалиста, даты и свободного временного слота с подтверждением записи. Мастер использует веб-интерфейс для просмотра ежедневного расписания, управления статусами записей (функции «Начать», «Завершить») и мониторинга персональной статистики. Администратор имеет полный доступ ко всем подсистемам: справочникам, управлению пользователями,

подтверждению записей и аналитическому модулю (доходы за период, загрузка специалистов, популярность услуг). Алгоритм поиска свободных слотов учитывает рабочее расписание мастеров, перерывы, праздничные дни и существующие активные записи, исключая конфликты двойного бронирования. Система автоматически обрабатывает просроченные записи, завершает услуги по истечении отведённого времени и формирует напоминания клиентам через очередь уведомлений. Безопасность обеспечивается хешированием паролей (bcrypt), защитой от CSRF- и XSS-атак, валидацией входных данных и подготовленными SQL-выражениями.

Научная новизна заключается в формализации архитектурного подхода, при котором интеграция с мессенджером выступает не внешней надстройкой, а нативным компонентом единого информационного контура управления бронированием. Предложенная модель предметно-ориентированной конфигурации обеспечивает развёртывание платформы в различных отраслях сферы услуг без модификации программного кода, что отличает решение от существующих коммерческих платформ с фиксированной предметной моделью.

Заключение. Спроектирована и реализована архитектура универсальной веб-платформы онлайн-записи на стеке PHP 8.2 / Laravel 10 / MySQL 8.0, объединяющей Telegram-бота и адаптивный веб-интерфейс в единой информационной среде. Механизм предметно-ориентированной конфигурации обеспечивает адаптацию системы к произвольной предметной области через административный интерфейс. Тестирование прототипа на примере салона красоты подтвердило работоспособность пошагового бронирования, ролевого разграничения доступа, автоматической смены статусов и системы уведомлений. Разработанное приложение для онлайн-записи и управления услугами может использоваться: в фитнес-клубах; в образовательных центрах; в салонах красоты и парикмахерских; в медицинских центрах; в любых организациях сферы услуг, где требуется ведение записи клиентов и управление расписанием сотрудников. Система обладает модульной архитектурой, что позволяет легко расширять ее функционал (добавлять новые типы услуг, интеграции с платёжными системами, SMS-рассылки) и масштабировать под растущую нагрузку.

Список литературы

1. Соммервилл, И. Инженерия программного обеспечения / И. Соммервилл. – 10-е изд. – Москва: Вильямс, 2020. – 960 с.
2. Автоматизация бизнес-процессов. – Текст: электронный // Business Automation Alliance: информационный портал. – URL: https://ba-alliance.org/ru/chto-takoe-avtomatizaciya-biznes-processov (дата обращения: 25.09.2026).
3. Таненбаум, Э. Компьютерные сети / Э. Таненбаум, Д. Уэзеролл. – 5-е изд. – Санкт-Петербург: Питер, 2019. – 960 с.
4. Laravel 10.x Documentation. – Текст: электронный // Laravel : официальный сайт. – URL: https://laravel.com/docs/10.x (дата обращения: 25.09.2026).

УДК 004.8

АРХИТЕКТУРА ИНТЕРАКТИВНОГО ВЕБ-СТЕНДА ДЛЯ МОДЕЛИРОВАНИЯ ФЕДЕРАТИВНОГО ОБУЧЕНИЯ EDGE AI В СЕТЯХ 6G

Котенко Ю.В., ORCID 0009-0008-4281-2572,
Лукашева С.Ю., ORCID 0009-0002-1425-2973
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
melin1989@mail.ru; sonyablabla24@yandex.ru

Введение. В концепции IMT-2030 искусственный интеллект рассматривается как прикладной сервис и средство повышения эффективности сети. Перенос обучения ближе к источникам данных сокращает задержку и объем обмена. Однако изучение Edge AI [2] средствами федеративного обучения требует навыков разработки, а программные фреймворки слабо показывают связь топологии, параметров каналов, ресурсов узлов и динамики обучения. Для учебных и исследовательских задач необходим инструмент, в котором сценарий собирается из готовых компонентов, а последствия изменения параметров наблюдаются сразу.

Цель работы состоит в разработке архитектуры интерактивного веб-стенда для моделирования федеративного обучения Edge AI в условиях сетей 6G. Стенд объединяет визуальный редактор, исполняемую модель обучения и накопление результатов. Он не эмулирует физический уровень, а позволяет воспроизводимо исследовать влияние задержки, пропускной способности, потерь, неоднородности ресурсов и распределения данных. Такой уровень абстракции сохраняет ключевые зависимости и делает сценарий доступным без написания кода.

Модель сценария. Сценарий представляется ориентированным графом G=(V, E). Множество V включает клиентские устройства, пограничные агрегаторы и облачный узел, а ребра E задают логические соединения. Для клиента задаются производительность, объем и класс локальных данных, доступная энергия; для соединения – задержка, пропускная способность и вероятность потери сообщения. Пользователь формирует граф перетаскиванием компонентов и редактирует параметры через панель свойств. Перед запуском система проверяет связность, наличие агрегатора и допустимость значений.

Вычислительное ядро реализует цикл федеративного обучения: выбор доступных клиентов, передачу глобальной модели, локальное обучение, моделирование сетевых и вычислительных задержек, прием обновлений и агрегацию. Базовым алгоритмом выбран FedAvg, в котором глобальные параметры на очередном раунде формируются как взвешенная по объему локальных выборок сумма клиентских обновлений [1]. При этом исходные данные не покидают устройство, а сервер получает только

параметры или градиенты. Событийная шкала визуализирует ожидание клиентов, передачу обновлений, выпадение узлов и момент агрегации. Пользователь может сопоставлять точность модели с длительностью раунда и коммуникационными затратами, а не рассматривать качество обучения изолированно.

Программная архитектура строится по трехуровневой схеме. Клиентская часть на React отвечает за сборку топологии и отображение метрик. Сервер приложений предоставляет REST-интерфейс и WebSocket-канал событий. Модуль на Python выполняет локальное обучение, агрегацию и расчет задержек; для прототипа могут использоваться PyTorch и Flower [3]. Разделение интерфейса и ядра позволяет подключать другие алгоритмы агрегации и модели сети без изменения редактора.

Реализованный прототип. На текущем этапе реализован пользовательский прототип стенда. Рабочая область содержит палитру компонентов «клиент», «пограничный узел» и «облако»; элементы добавляются на схему и перемещаются методом drag-and-drop. Для каждого клиента задаются вычислительная мощность и доля данных, а для канала – задержка, пропускная способность и доля потерь. Параметры IID/Non-IID распределения, коэффициент Дирихле и число раундов изменяются до запуска. В процессе моделирования интерфейс отображает передачу обновлений, номер раунда и состояние узлов, после завершения – кривые точности и функции потерь, задержку и сетевой трафик. Сценарий и история запуска сохраняются в реляционной базе данных. Поэтому один эксперимент можно воспроизвести и сопоставить с вариантом, в котором изменен только один фактор.

Подсистема хранения данных является функционально необходимой частью стенда. В реляционной базе данных предлагается хранить версии сценариев, параметры узлов и связей, конфигурации запусков, метрики раундов и показатели клиентов. Сущности Scenario, Node и Link фиксируют топологию; Run связывает запуск с версией сценария и seed; RoundMetric и ClientMetric содержат точность, функцию потерь, длительность и объем обмена. Такая структура обеспечивает повторяемость и сравнение запусков. Для локального прототипа достаточно SQLite, а при многопользовательской работе схема переносится в PostgreSQL. LLM не включается в обязательный контур: позднее она может объяснять графики, а RAG и векторное хранилище потребуются только для поиска по учебным материалам.

Методика эксперимента предусматривает использование наборов MNIST или EMNIST и компактной сверточной сети. Данные распределяются между 5–30 виртуальными клиентами по двум схемам: равномерной IID и неоднородной Non-IID. Степень неоднородности задается параметром распределения Дирихле. Для каждого сценария фиксируются число локальных эпох, доля участвующих клиентов,

скорость каналов и относительная производительность устройств. Сравниваются однородная конфигурация, сценарий с медленными клиентами и сценарий с ограниченными каналами. Все запуски выполняются с сохранением начального состояния и seed, что позволяет отделить влияние исследуемого фактора от случайного разброса.

Критериями оценки выбраны точность, функция потерь, число раундов до заданного качества, время обучения, объем обмена, задержка раунда и доля завершивших обучение клиентов. FedAvg планируется сравнить с ресурсно-ориентированным выбором участников по задержке, вычислительной мощности и объему выборки [4]. Гипотеза состоит в том, что исключение медленных клиентов сокращает раунд, но чрезмерный отбор ухудшает представительность данных и итоговое качество. Стенд должен позволить наблюдать этот компромисс и сохранять результаты для анализа.

Научная новизна состоит в объединении визуального конструирования коммуникационно-вычислительного сценария, событийного моделирования федеративного цикла и воспроизводимого хранения результатов в едином веб-инструменте. Объектом анализа становится взаимное влияние топологии, сетевых ограничений, неоднородности ресурсов и распределения данных. Стенд может применяться в лабораторных работах и для предварительной проверки стратегий выбора клиентов без развертывания реальной беспроводной инфраструктуры.

Заключение. Предложена архитектура веб-стенда для сборки сценария методом drag-and-drop, моделирования федеративного обучения и сопоставления качества модели с сетевыми и вычислительными затратами. Реализован пользовательский прототип редактора с визуализацией метрик и сохранением сценариев. База данных обоснована задачами версионирования и воспроизводимости. Следующий этап – подключение полноценного вычислительного ядра на основе FedAvg, наборов MNIST/EMNIST и проведение серии контролируемых экспериментов.

Список литературы

1. McMahan B. Communication-efficient learning of deep networks from decentralized data / B. McMahan, E. Moore, D. Ramage [et al.] // Proceedings of the 20th International Conference on Artificial Intelligence and Statistics. – 2017. – Vol. 54. – P. 1273-1282. – URL: https://proceedings.mlr.press/v54/mcmahan17a.html (дата обращения: 25.09.2026).
2. Letaief K. B. Edge artificial intelligence for 6G: vision, enabling technologies, and applications / K. B. Letaief, Y. Shi, J. Lu, J. Lu // IEEE Journal on Selected Areas in Communications. – 2022. – Vol. 40, no. 1. – P. 5-36. – DOI 10.1109/JSAC.2021.3126076.
3. Flower: a friendly federated learning research framework / D. J. Beutel, T. Topal, A. Mathur [et al.].– 2020. – arXiv:2007.14390. – Текст: электронный. – URL: https://arxiv.org/abs/2007.14390 (дата обращения: 25.09.2026).
4. Liu Y. Federated learning for 6G communications: challenges, methods, and future directions / Y. Liu, X. Yuan, Z. Xiong [et al.] // China Communications. – 2020. – Vol. 17, no. 9. – P. 105-118. – DOI 10.23919/JCC.2020.09.009.

УДК 004.896:621.65

РАЗРАБОТКА И ИССЛЕДОВАНИЕ IIoT-СИСТЕМЫ МОНИТОРИНГА И АНАЛИЗА ЭНЕРГОПОТРЕБЛЕНИЯ ОБОРУДОВАНИЯ

Кузовков Д.А., ORCID 0009-0000-4772-4426,
Заргарян Е.В., канд. техн. наук, доц., ORCID 0000-0002-8921-4085
ФГБОУ ВО «Южный федеральный университет», г. Таганрог, РФ
kuzovkov@sfedu.ru, evzargaryan@sfedu.ru

Введение. Насосные станции, компрессорные цеха – это, по сути, главные потребители электричества на любом предприятии нефтегаза или энергетики. До 60–70 % всей нагрузки. Штатные АСУ ТП, которые там стоят, конечно, контролируют технологические параметры – давление, температуру, расход. Но вот глубокого анализа энергоэффективности в онлайне они не дают. Получается парадокс: данные есть, а инструмента для работы с ними нет. Отсюда и возникает потребность в переходе от простого мониторинга к проактивному управлению – через промышленный интернет вещей и цифровые двойники [1–3].

Цель спроектировать архитектуру IIoT-платформы, которая бы совмещала непрерывный телеметрический контроль агрегатов с модулем динамического моделирования в среде моделирования Engee. И, соответственно, оценить, насколько такой подход применим для задач энергосбережения. Основная часть. Если посмотреть на то, что сейчас внедряют на промышленных площадках, то большинство систем энерго-учета сводится к банальному сбору данных со счетчиков и построению трендов. Фиксируют факт потребления – и всё. А почему потребляют именно столько, где резервы – это уже за рамками. IIoT-архитектура как раз и позволяет закрыть этот разрыв, объединив телеметрию, аналитику и цифровое моделирование в единый контур [2, 6–7].

Основная часть. Разрабатываемая система построена по трехуровневой схеме. Полевой ярус. На оборудовании – в данном случае на магистральных насосных агрегатах – размещается комплекс датчиков. Виброакустические сенсоры и термопары подшипниковых опор, термосопротивления обмоток статора, преобразователи напора и расхода, счетчики активной энергии (они включены в периметр АСУЭ). Всё это дает сырые данные и передаёт на средний уровень.

Средний уровень (Edge-устройства) включает промышленные шлюзы и контроллеры, которые осуществляют первичную агрегацию данных, фильтрацию шумов и преобразование промышленных протоколов (Modbus RTU, HART) в стандартные сетевые протоколы (OPC UA, MQTT) для передачи на верхний уровень.

Верхний уровень. Он находится на сервере предприятия и имеет SCADA-панель для оператора, базу данных временных рядов и модуль

аналитики. Система непрерывно следит за энергопотреблением насосов. Она сравнивает текущую мощность с идеальной моделью, которая подстраивается под текущие задачи: давление, плотность продукта и нагрузку. Чтобы система не паниковала из-за кратковременных скачков напряжения при запуске, порог чувствительности будет установлен в +5%.

Для повышения глубины анализа в систему интегрирован модуль цифрового моделирования. В отличие от традиционных подходов, где моделирование проводится автономно, в данной работе используется среда динамического моделирования Engee. Цифровая модель расматриваемого оборудования, разработанная в среде моделирования Engee, содержит гидравлические и электромеханические характеристики насосных агрегатов и трубопроводов. IIoT-платформа непрерывно передает в среде моделирования Engee актуальные входные параметры (расход, давление, температуру, вязкость среды). На основе этих данных цифровой двойник в фоновом режиме рассчитывает требуемые напоры, частоты вращения и оптимальную конфигурацию работающего оборудования [3].

Результатом работы связки «IIoT-мониторинг + Engee» является то, что система автоматически инициирует пересчет параметров цифрового двойника и актуализацию целевых показателей энергопотребления, для дальнейших этапов исследований.

Исследование показало, что использование IIoT-архитектуры позволяет обеспечить высокую скорость отклика системы (период опроса критических параметров составляет от 1 до 5 секунд) и масштабируемость. Интеграция со средой моделирования Engee позволяет учитывать нелинейные характеристики исследуемого оборудования и износ узлов, которые трудно описать жесткими и четкими математическими формулами в классических программируемых логических контроллерах.

Заключение. В работе рассмотрена концепция промышленной IIoT-платформы для контроля работы динамического оборудования и анализа потребления электроэнергии. Предлагаемая система объединяет получение данных от технологических датчиков и приборов учета, их предварительную обработку, хранение и последующий анализ. Отдельное место в архитектуре занимает математическая модель оборудования, реализуемая в среде Engee. Передача в модель текущих технологических параметров позволяет выполнять расчеты для фактических условий эксплуатации, а не использовать только заранее заданные значения.

В результате объединения телеметрии и математического моделирования появляется возможность выявлять отклонения энергопотребления и дополнительно анализировать причины их возникновения. Полученные результаты могут использоваться оператором при оценке режима работы насосного оборудования. В дальнейшем предложенную концепцию можно проверить на реальном промышленном объекте. При этом потребуется уточнить математическую модель

конкретного насосного агрегата, определить состав необходимых датчиков и накопить экспериментальные данные. Использование этих данных позволит проверить точность расчетов и при необходимости скорректировать алгоритмы оценки энергетической эффективности.

Список литературы

1. Заргарян, Е. В. Выявление источников загрязнения воздуха с помощью методов кластеризации и обратного моделирования / Е. В. Заргарян, Т. А. Сухов, Д. Д. Козачук // Перспективы автоматизации. Рациональное управление. Связь и акустика: сборник трудов XIV Всероссийской научной конференции. – Геленджик, 2025. – С. 85–89.
2. Сухов, Т. А. Программная реализация алгоритмов формирования контура объекта препятствия в зоне видимости камеры робота-манипулятора / Т. А. Сухов // Информационные технологии, системный анализ и управление (ИТСАУ-2024): сборник трудов XXII Всероссийской научной конференции молодых ученых, аспирантов и студентов. – Таганрог, 2024. – Т. 1. – С. 275–278.
3. Пушнина, И. В. Управление водными ресурсами: принципы, модели и примеры применения в России / И. В. Пушнина, В. А. Блинцов // Инженерия – XXI: сборник трудов международной молодежной школы. – Новороссийск, 2025. – С. 122–123.
4. Заргарян, В. Ю. Интернет транспортных средств: инновации и возможности использования / В. Ю. Заргарян, И. В. Пушнина // Проблемы автоматизации. Региональное управление. Связь и акустика: сборник трудов XIII Всероссийской научной конференции и молодежного научного форума. – Ростов-на-Дону; Таганрог, 2024. – С. 309–313.
5. Заргарян, Е. В. Эффекты применения технологий IIoT в системах интеллектуального управления освещением на производстве / Е. В. Заргарян, Е. С. Филонова // Прикладные вопросы точных наук: материалы VII Международной научно-практической конференции студентов, аспирантов, преподавателей. – 2023. – С. 121–124.
6. Сухов, Т. А. Разработка и валидация низкобюджетных сенсоров для мониторинга PM2.5 и NO в городской среде / Т. А. Сухов, В. Ю. Заргарян // Наука Юга России: достижения и перспективы: тезисы докладов. – Ростов-на-Дону, 2026. – С. 363.
7. Грязнова, А. И. Новые технологии в информационной системе / А. И. Грязнова, А. В. Ганциевский // Наука и современность: сборник статей Всероссийской научно-практической конференции студентов и молодых ученых. – Таганрог, 2023. – С. 58–60.

УДК 004.65

ОПТИМИЗАЦИЯ ХРАНЕНИЯ МЕТАДАННЫХ АКТИВНОСТИ АБОНЕНТОВ В СЕТИ ИНТЕРНЕТ

Лакиза А.С., ORCID 0009-0003-2830-5121
ФГБНУ «Институт проблем искусственного интеллекта», г. Донецк, РФ
off.lakiza@yandex.ru

Введение. Одной из важных задач для оператора связи является хранение метаданных активности абонентов в сети Интернет. Анализ метаданных используется в целях поиска аномалий, изучения источников трафика, выдачи информации по запросу правоохранительных органов. Метаданные активности в сети Интернет собираются по протоколу Netflow [1]. Занимаемый объём дискового пространства такими данными может быть значительным.

Одним из популярным средств сбора данных по протоколу Netflow является утилита nfcapd из пакета nfdump [2]. Данный сервис формирует файлы с данными в указанный временной интервал (например, 1 час). Одним из недостатков такого формата хранения является то, что поиск по всему массиву данных в определённых ситуациях может занимать несколько суток. Кроме того, в отдельных ситуациях возникает необходимость выбирать меньшую степень сжатия встроенными средствами, чтобы сервис вовремя обрабатывал поступающие данные, что увеличивает итоговый объём хранимой информации. Потеря даже одного пакета данных критична.

Предлагается использовать специализированные базы данных для аналитики, например, Clickhouse [3]. Эта колоночная база данных, за счёт чего становится возможным быстрый поиск по массиву данных, а также применение различных алгоритмов обработки и сжатия данных, наиболее эффективных в каждом столбце таблицы [4].

Цель работы – изучение возможностей применения СУБД Clickhouse для оптимизации хранения метаданных активности в сети Интернет.

Доступные алгоритмы для применения в обработке данных Netflow включают в себя: ZSTD, LZ4, LZ4HC, Delta, DoubleDelta, T64.

Для определения эффективности сжатия посредством БД был проведен эксперимент, в ходе которого применяли различные алгоритмы сжатия к столбцам таблицы и увеличивали уровни сжатия. Применяли следующие алгоритмы и уровни сжатия:

- LZ4;
- ZSTD (с уровнями сжатия от 1 до 22);
- LZ4HC (с уровнями сжатия от 1 до 12);

• T64 + ZSTD (с уровнями сжатия от 1 до 22);
• T64 + LZ4HC (с уровнями сжатия от 1 до 12);

После каждого изменения вычисляли отношение размера оригинальных файлов nfcapd к размеру таблицы в Clickhouse за аналогичный период. Сравнение различных алгоритмов сжатия представлено на рисунке 1.

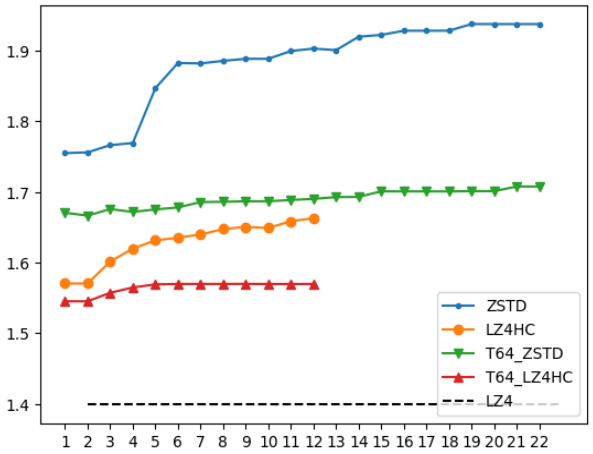


Рис. 1. Отношение размера файлов nfcapd к размеру данных в БД

Во время анализа степени сжатия каждого столбца в отдельности после применения различных алгоритмов сжатия, было обнаружено, что применение ZSTD со степенью сжатия больше 7 не приводит к значительным изменениям в объёме данных. Также обнаружено, что применение кодека T64 с последующим применением ZSTD для некоторых столбцов дало прирост в степени сжатия.

Путём применения ZSTD с уровнем сжатия 8 и предобработки алгоритмом T64 для нескольких столбцов получилось увеличить эффективность сжатия на 3.5 % по сравнению с применением ZSTD на все столбцы, и на 39.5 % по сравнению с применением LZ4 (настройки по умолчанию). Итоговое отношение данных в формате nfcapd к данным в БД, сжатым комбинированным подходом составило 1.95.

Итоговое сравнение алгоритмов сжатия представлено на рисунке 2.

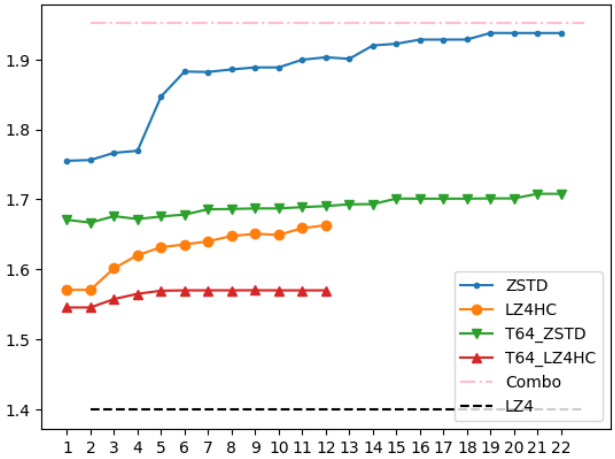


Рис. 2. Отношение размера файлов nfcapd к размеру данных в БД

Заключение. Перенос данных из формата nfcapd в базу данных Clickhouse способен уменьшить размер занимаемого дискового пространства. Кроме того, тонкая настройка алгоритмов сжатия позволяет добиться лучших результатов. В дополнение к уменьшению занимаемого дискового пространства, увеличивается скорость поиска необходимой информации, что делает этот подход к оптимизации перспективным.

Список литературы

1. Cisco Systems NetFlow Services Export Version 9 – Текст: электронный // IETF.: официальный сайт. – URL: https://www.ietf.org/rfc/rfc3954.txt (дата обращения: 11.02.2026).
2. Netflow processing tools – Текст: электронный // Github.: официальный сайт. – URL: https://github.com/phaag/nfdump/tree/master (дата обращения 11.02.2026).
3. Fast Open-Source OLAP DBMS | ClickHouse – Текст: электронный // Clickhouse.: официальный сайт. – URL: https://clickhouse.com/ (дата обращения 11.02.2026).
4. Сжатие в ClickHouse | ClickHouse Docs – Текст: электронный // Clickhouse. : официальный сайт. – URL: https://clickhouse.com/docs/ru/data-compression/compression-in-clickhouse (дата обращения 11.02.2026).

УДК 004.94:504.064:528.94:528.952

ЭКОСИСТЕМНЫЙ ПОДХОД В СИТУАЦИОННОМ МОДЕЛИРОВАНИИ ДЛЯ ЦЕЛЕЙ МОНИТОРИНГА ОКРУЖАЮЩЕЙ СРЕДЫ

Латкин В.А., ORCID 0000-0002-9353-0662
ФГБОУ ВО «Алтайский государственный университет», г. Барнаул, РФ
latkinvadim@mail.ru

Введение. Мониторинг окружающей среды предполагает получение полной и точной информации для последующего принятия решений – то, что принято обозначать термином «ситуационная осведомлённость» («Situational Awareness»), сформировавшимся на рубеже 1990-х годов и связанным в первую очередь с работами Мика Эндсли.

Для ситуационного управления требуются достаточно большие затраты на предварительное создание базы знаний об объекте управления, его функционировании и способах управления им [1]. Для описания объектов осуществляется процесс моделирования – создания знаковых моделей в контексте экосистемного подхода.

Цель исследования – разработка концепции модельной экосистемы ситуационной осведомлённости для целей мониторинга окружающей среды.

Задачи: 1) Проанализировать необходимость ситуационной осведомлённости и системе экологического мониторинга.

2) Разработать структуру модельной экосистемы ситуационной осведомлённости.

3) Определить программное обеспечение и исходные данные, необходимые для создания различных моделей.

Основная часть. Общие принципы *ситуационной осведомлённости (СО)* становятся реалистичными только применительно к конкретной модели принятия решений в той или иной предметной области. Говоря о здоровье и благополучии населения в целом, формировании благоприятной окружающей среды и, как следствие, возможности осуществления любой деятельности, в первую очередь необходимо обеспечение СО в экологической отрасли.

Осведомлённость в области экологии помимо решения задачи достижения безопасной среды обитания важна и с точки зрения её поддержания в таком состоянии как показатель уровня экологической культуры – степени духовного развития общества, нравственности населения.

Для эффективного ситуационного управления возникает необходимость разработки совокупности взаимосвязанных и взаимодополняемых моделей, образующих геопространственную среду для пользователя и позволяющих адекватно оценить и предсказать состояние объекта, подчинённых трём главным задачам экологического мониторинга: наблюдению, оценке, прогнозу. Такую совокупность разнообразных моделей предлагается обозначить термином «модельная экосистема». Слово «экосистема» используется не в прямом смысле (не связано напрямую с экологией), а в переносном – как система (целое, составленное из взаимосвязанных частей), образующая среду («эко») вокруг человека (пользователя) в определённом направлении деятельности в современном технологическом мире – в данном случае в отношении ситуационной осведомлённости. В целом, геопространственные среды (экосистемы) сегодня являются «одним из технологических прорывов, происходящих в геоиндустрии» [2, с. 113].

Для целей экологического мониторинга автором разработана структурная схема *модельной экосистемы ситуационной осведомлённости (МЭСО)*, включающая тесно взаимосвязанные виды моделей (рис.).

Для получения обозначенных на схеме моделей используется следующее *программное обеспечение*: геоинформационные системы «MapInfo Professional»/«Аксиома» и «QGIS», графический редактор игрового движка «Prism3D».

Исходными данными для моделирования являются: электронные векторные и растровые карты, цифровые модели рельефа, спутниковые снимки, материалы наземной съёмки, информация с датчиков, от очевидцев, с веб-ресурсов (сайтов) официальных лиц (органов власти).

Заключение. Ситуационная осведомлённость – это внутренняя ментальная модель состояния окружающей среды, которая строится путём применения системных знаний [3]. При мониторинге для формирования

осведомлённости о ситуации на определённой территории, принятия решений и последующего осуществления практических мероприятий по улучшению экологического состояния необходимо системное моделирование для возможности подробного анализа, планирования, проектирования – разработка модельной экосистемы ситуационной осведомлённости (МЭСО) с использованием определённого программного обеспечения (ГИС, игровые движки).

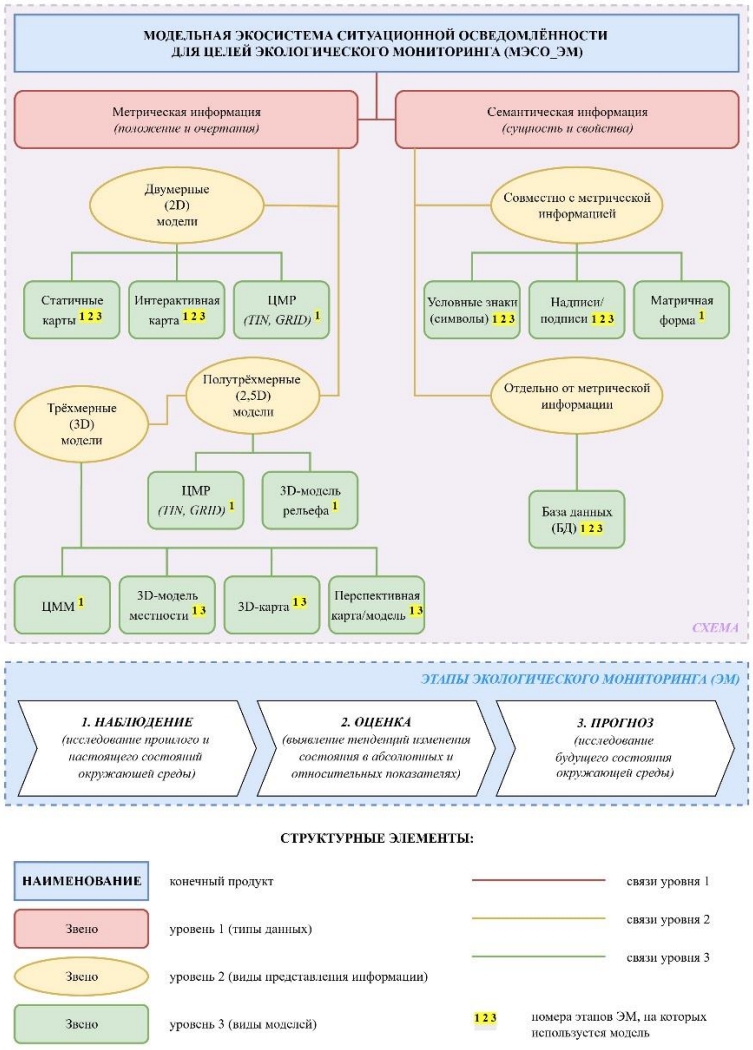


Рис. Структурная схема МЭСО для целей экологического мониторинга

Наиболее наглядны для пользователей графические образно-знаковые информационные модели. Среди них более доступными и дешёвыми являются модели, отображаемые плоских дисплеях (мониторах, планшетах). При этом графическое представление аналогов реальных объектов, процессов и явлений может быть как в ортогональной проекции (двумерный, или 2D-вид, два измерения – X, Y), так и в центральной (трёхмерный, или 3D-вид, три измерения – X,Y,Z(H). Каждый вид моделей обладает индивидуальными свойствами, отличительными особенностями (уникальностью), за счёт чего в МЭСО они являются взаимодополняемыми.

Проведённое исследование вносит вклад в развитие ситуационного управления в части геоинформационного и картографического обеспечения ситуационной осведомлённости в области экологического мониторинга.

Список литературы

1. Массель, Л. В. Ситуационное управление и семантическое моделирование в энергетике / Л. В. Массель, А. Г. Массель // Открытые семантические технологии проектирования интеллектуальных систем. – Минск, 2014. – № 4. – С. 111–116. – EDN: ZIGJBZ.
2. Пошивайло, Я. Г. Современные тенденции, проблемы и задачи картографии / Я. Г. Пошивайло // Вестник СГУГиТ. – Новосибирск: СГУГиТ, 2026. – Т. 31, №3. – С. 108–120. – DOI 10.33764/2411-1759-2026-31-3-108-120. – EDN: LHDGIH.
3. Фридман, А. Я. Ситуационная осведомлённость при моделировании промышленно-природных комплексов / А. Я. Фридман // Теория и практика системной динамики: сб. материалов VIII Всероссийской конференции с международным участием (Апатиты, 1–5 апреля 2019 г.). – Апатиты: Кольский научный центр Российской академии наук, 2019. – С. 169–173. – EDN: OBUUOS.

УДК 004.932

КРИТЕРИИ ВЫБОРА НЕЙРОСЕТЕВОЙ МОДЕЛИ ИДЕНТИФИКАЦИИ ОБЪЕКТОВ ДЛЯ ПОИСКОВО-СПАСАТЕЛЬНОЙ СИСТЕМЫ БПЛА

Лисина Т.Б., ORCID 0009-0007-6681-3652,
Тумбинская М.В., канд. техн. наук, доц., ORCID 0000-0003-3738-5242
ФГБОУ ВО «Казанский национальный исследовательский технический университет – Казанский авиационный институт им. А. Н. Туполева», г. Казань, РФ
tatyana.lisina.04@mail.ru, tumbinskaya@inbox.ru

Введение. В задачах поисково-спасательных операций БПЛА должны быстро обнаруживать людей, животных и признаки присутствия человека на местности. Однако аэрофотосъёмка создаёт дополнительные сложности: объекты часто являются мелкими, съёмка ведётся сверху вниз, возможны размытие кадра, погодные помехи, изменение освещения и искажения широкоугольной оптики. Стандартные датасеты, такие как COCO [1], содержат классы person, cat, dog и другие, но не решают задачи детальной идентификации пола, частей тела. Для таких сценариев более релевантным является бенчмарк VisDrone [2]. В распределённой группе БПЛА также важно учитывать ограничения бортовых вычислений, энергии и связи, поэтому нейросетевой модуль должен работать локально и передавать в сеть не видеопоток, а компактные метаданные.

Цель – сформулировать критерии выбора нейросетевой модели идентификации объектов для поисково-спасательной системы БПЛА.

Основная часть. Задачу идентификации целесообразно разделить на уровни. На первом уровне выполняется быстрая детекция объектов: человек, животное, транспорт или другой объект на местности. На втором уровне при наличии ресурсов выполняется классификация атрибутов человека, например позы, состояния или видимых частей тела. На третьем уровне может применяться сегментация частей тела и волос, относящаяся к задаче human parsing [5]. Для животных и биологических текстур могут использоваться расширенные датасеты, например Animal Kingdom [7], однако прямое различение «волосы человека» и «шерсть животного» по одному кадру с БПЛА остаётся сложной специализированной задачей**.**

Подзадача	Что идентифицируется	Типовые архитектуры	Датасеты	Ограничения для БПЛА
Детекция объекта	Человек, животное, транспорт	YOLOv7 [3], Swin-based detectors [4]	COCO [1], VisDrone [2]	Мелкие объекты, высота полёта, размытие
Атрибуты человека	Поза, состояние, признаки человека	Лёгкие CNN, MobileNetV3 [6]	VisDrone [2], специализированные SAR-данные	Низкое разрешение, неполная видимость
Human parsing	Голова, руки, ноги, торс, волосы	Сегментационные модели [5]	LIP [5]	Высокая вычислительная стоимость
Животные и текстуры	Вид животного, шерсть, биологические признаки	Детекторы и сегментаторы	Animal Kingdom [7]	Нет универсального класса «шерсть»
Edge-обработка	Локальная реакция без сервера	MobileNetV3 [6], лёгкие YOLO [3]	Зависит от задачи	Ограниченная память, батарея, нагрев

Для распределённой SAR-системы БПЛА нейросетевая модель должна выбираться не только по точности, но и по системным характеристикам. Основные критерии:

1. Точность на мелких объектах. Человек или животное с высоты 50–100 м может занимать менее 32×32 пикселей. Поэтому общая метрика mAP недостаточна: важно оценивать точность на мелких объектах, например mAP_{small} или recall. Датасет VisDrone [2] показывает, что стандартные подходы теряют эффективность сценариях.

2. Задержка обработки кадра. Если БПЛА обнаружил человека, информация должна быть передана группе до выхода цели из зоны видимости. Необходимо учитывать полную задержку: захват кадра, предобработку, инференс, постобработку и формирование сообщения.

3. Размер модели. Бортовые компьютеры малых БПЛА имеют ограниченную память и вычислительные ресурсы. Большие

трансформерные модели [4] могут давать высокую точность, но быть непригодными для реального времени на дроне. Лёгкие архитектуры, такие как MobileNetV3 [6], лучше подходят для edge-устройств.

4. Энергопотребление. Время полёта БПЛА ограничено батареей. Запуск нейросети потребляет энергию процессора, памяти и системы охлаждения. В SAR-задачах более лёгкая модель с немного меньшей точностью может быть предпочтительнее тяжёлой модели, которая быстро разряжает аккумулятор.

5. Коммуникационная нагрузка. Каждый агент должен передавать компактные метаданные: класс объекта, координаты, уверенность модели, видимые части тела, состояние сенсора и временную метку. Это снижает нагрузку и повышает отказоустойчивость системы.

На основании рассмотренных критериев предлагается следующая схема. Первый уровень – быстрая локальная детекция с помощью лёгкой модели. Второй уровень – выборочная классификация атрибутов, если объект имеет достаточное разрешение и уверенность детектора высока. Третий уровень – сегментация частей тела и волос по подходам human parsing [5], запускаемая только при наличии вычислительного резерва. Для животных используется отдельная ветвь классификации или детекции. Результат идентификации передаётся в распределённую систему в виде компактного сообщения, которое используется агентами для перераспределения маршрутов и подтверждения обнаружения цели.

Заключение. Анализ показал, что для распределённой SAR-систем БПЛА не существует одной универсальной нейросетевой модели. Целесообразно использовать каскадную систему: быстрая детекция, выборочная классификация атрибутов и сегментация частей тела при необходимости. Предложенный подход позволяет применять лёгкие нейросетевые модели на борту БПЛА и передавать в группу только метаданные о целях**.**

Список литературы

1. Lin T.-Y. Microsoft COCO: Common Objects in Context / T.-Y. Lin, M. Maire, S. Belongie [et al.] // Computer Vision – ECCV 2014: 13th European Conference on Computer Vision. – Cham: Springer, 2014. – Vol. 8693. – P. 740–755. DOI: 10.48550/arXiv.1405.0312
2. Zhu P. Vision Meets Drones: A Challenge / P. Zhu, L. Wen, X. Bian [et al.] // arXiv preprint arXiv:1804.07437. 2018. DOI: 10.48550/arXiv.1804.07437
3. Wang C.-Y. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors / C.-Y. Wang, A. Bochkovskiy, H.-Y. M. Liao // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2023. – P. 7464–7475. DOI: 10.1109/CVPR52729.2023.00721
4. Liu Z. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows / Z. Liu, Y. Lin, Y. Cao [et al.] // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 10012–10022. DOI: 10.1109/ICCV48922.2021.00986
5. Gong K. Look into Person: Self-Supervised Structure-Sensitive Learning and a New Benchmark for Human Parsing / K. Gong, X. Liang, D. Zhang [et al.] // Proceedings of the

IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2017. – P. 932–940. DOI: 10.48550/arXiv.1703.05446
6. Howard A. Searching for MobileNetV3 / A. Howard, M. Sandler, G. Chu [et al.] // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). – 2019. – P. 1314–1324. DOI: 10.1109/ICCV.2019.00140
7. Ng X. L. Animal Kingdom: A Large and Diverse Dataset for Animal Behavior Understanding / X. L. Ng, K. E. Ong, Q. Zheng [et al.] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2022. – P. 19023–19034. DOI: 10.1109/CVPR52688.2022.01844

УДК 004.358:629.051:623.746.4-519

АНАЛИЗ ЗАДЕРЖЕК И СТАБИЛЬНОСТИ ПЕРЕДАЧИ ИНЕРЦИАЛЬНЫХ ДАННЫХ ПО КАНАЛУ WI-FI НА БАЗЕ ПРОТОКОЛА MODBUS TCP В СРЕДЕ SCADA TRACE MODE 7

Ломонос Г.Т., ORCID 0009-0000-9759-0008,
Онопко Н.В., Юраш М.И.
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
lomonos.gn@gmail.com, nik.onopko.24@mail.ru, m.yurash.maks@gmail.com

Введение. Бытует мнение, что SCADA-системы предназначены лишь только для автоматизации технологических процессов, однако по утверждению разработчиков SCADA TRACE MODE 7 ООО «АдАстрА» может эффективно применяться и на испытательных стендах, и в автоматизированных системах научных исследований (АСНИ). TRACE MODE 7 позволяет автоматизировать полный цикл испытаний – разработать автоматические процедуры, вести измерения, записывать и обрабатывать данные, формировать отчеты [1].

Цель работы. В последнее время для мониторинга инфраструктуры, сельскохозяйственных угодий, инспекций, поисково-спасательных операций, а также в образовательных и любительских проектах всё шире применяются лёгкие БПЛА и легкомоторная авиация. Эффективность таких задач зависит от сбора и анализа полётных данных о движении аппарата, состоянии его систем и параметрах окружающей среды. Поэтому актуальна разработка беспроводных распределённых систем сбора полётных данных (ССПД) на базе доступных микроконтроллеров. Целью данной работы является применения SCADA TRACE MODE 7 (TM7) не только в качестве диспетчерского пункта сбора данных от измерительного микроконтроллерного устройства на ESP32, но и проведения анализа задержек и стабильности передачи высокочастотных инерциальных данных по каналу Wi-Fi на базе протокола Modbus TCP.

Основная часть. Измеряемые параметры полетной телеметрии: крен, тангаж, курс, высота, вариометр. В качестве инерциального

измерительного блока (IMU) используется 9-осевой модуль LSM9DS1. Этот модуль объединяет сразу три датчика: трёхмерный акселерометр, трёхмерный гироскоп, трёхмерный магнитометр с подключением в системе по интерфейсу SPI для обеспечения стабильности и высокой скорости опроса данных до 10 МГц. Измерение высоты обеспечивает датчик BME280, измеряющий атмосферное давление и обеспечивающий опрос данных по интерфейсу I²C до 3,4 МГц.

Для исключения влияния стороннего сетевого трафика и минимизации погрешности измерений, вносимой коммутационным оборудованием общего пользования организована изолированная беспроводная сеть типа «точка-точка» (P2P), в которой микроконтроллер ESP32 выполняет роль Modbus TCP-сервера и точки доступа (SoftAP), что позволило исследовать вычислительные задержки сетевого стека в чистом виде. Предусмотрены регистры управления для команд из SCADA менять программные задержки, частоту дискретизации фильтра, отключать вывод графики на экран для оценки «чистой» сетевой производительности.

На данном этапе анализа предусмотрены три режима экспериментов: базовый режим с включённым экраном, режим без отрисовки экрана и турбо опрос с задержкой delay(1) вместо установленной 15мс. Тракт передачи полного цикла доставки одного отсчёта включает следующие этапы:

1. **Сбор данных с датчиков.** Микроконтроллер ESP32 осуществляет циклический опрос инерциального датчика LSM9DS1 и барометра BME280.

2. **Вычисление измеряемых параметров.** В теле основного цикла loop() программы ESP32 из сырых данных рассчитываются физические величины: крен, тангаж, курс, высота и скорость изменения высоты. Результаты размещаются в holding-регистрах Modbus TCP-сервера.

3. **Отрисовка TFT-дисплея.** Параллельно в том же цикле выполняется или не выполняется по команде из SCADA обновление графического интерфейса на TFT-дисплее ILI9341, что вносит дополнительный временной вклад во время выполнения цикла.

4. **Формирование маркера цикла.** В отдельный регистр Modbus записывается значение счётчика пакетов – инкрементируемого на каждой итерации loop() маркера, однозначно идентифицирующего текущий цикл сбора данных. Это позволяет на стороне SCADA-системы сопоставлять количество сформированных ESP32 отсчётов с количеством успешно доставленных.

5. **Период выполнения цикла.** Программная задержка delay(15) в сочетании с временем опроса датчиков, вычисления параметров и отрисовки дисплея составляет в сумме около 20 мс на один полный цикл loop(). Таким образом, частота формирования отсчётов на стороне ESP32 составляет 45–50 Гц.

6. **Запрос SCADA-клиента.** Среда Trace Mode 7, выступающая в роли Modbus TCP-клиента (master), инициирует циклический опрос

регистров ESP32 по беспроводному Wi-Fi-каналу с периодом сканирования 20 мс.

7. **Передача по каналу Wi-Fi (P2P):** ESP32 (SoftAP) ↔ Wi-Fi-адаптер ПК с SCADA-системой.

8. **Вывод трендов счётчиков пакетов и запись в архив ТМ7.** Принятые значения обрабатываются под управлением МРВ ТМ7 и фиксируются в архиве системы с временной меткой для последующей обработки. Счётчик опросов Modbus TCP, формируемый средствами ТМ7, записывается параллельно с принятым значением регистра счётчика пакетов ESP32.

Для оценки задержек и стабильности канала связи в ТМ7 организовано одновременное отображение трендов двух счётчиков: счётчика пакетов, формируемого в ESP32 (красная линия тренда) и счётчика опросов Modbus TCP, генерируемого внутри ТМ7 (синяя линия тренда). Сравнение этих трендов позволяет визуально и количественно определить расхождения, вызванные задержками доставки, потерями пакетов и джиттером беспроводного канала. На рис. приведен пример непрерывной работы трёх режимов вычислительной нагрузки микроконтроллера.

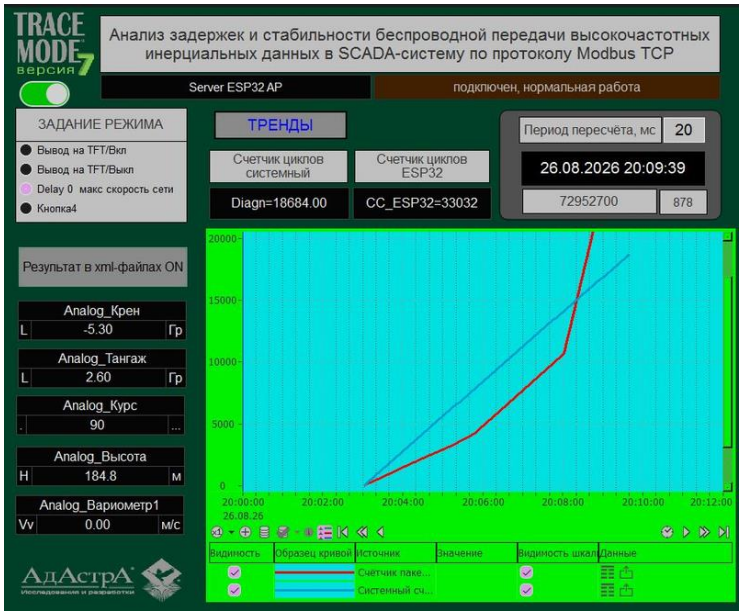


Рис. Совмещённый тренд трёх экспериментальных режимов

В первой фазе (до 20:06:00) при активности SPI-интерфейса дисплея частота генерации данных составляет 22.2 Гц. Перевод системы в чисто телеметрический режим (интервал 20:06:00 – 20:08:00) приводит к мгновенному изменению угла наклона тренда и росту частоты до 54.1Гц, что экспериментально подтверждает гипотезу о высокой ресурсоемкости графического рендеринга (накладные расходы шины SPI составляют 26.5 мс на кадр). Активация режима предельной производительности (после

20:08:00) характеризуется взрывным ростом частоты итераций до 158.3 Гц. Непрерывность и идеальная линейность всех трех участков тренда доказывают высокую стабильность разработанной архитектуры.

Заключение. Разработанная ССПД предоставляет возможность зафиксировать процент потерянных пакетов и микро-задержек, определить рекомендации по выбору частоты опроса SCADA для сохранения стабильности потока данных, может быть использована для построения высокоскоростных беспроводных полетных самописцев.

Список литературы

1. Автоматизация испытательных стендов в SCADA TRACE MODE 7. – Текст: электронный. – URL: https://www.tracemode.ru/products/articles/ispit (дата обращения: 08.04.2026).

УДК 004.932.72'1

МЕТОДЫ ПОВЫШЕНИЯ РОБАСТНОСТИ 3D-ОЦЕНКИ ПОЗЫ ЧЕЛОВЕКА К ОККЛЮЗИЯМ ДЛЯ АНАЛИЗА ДВИГАТЕЛЬНОЙ АКТИВНОСТИ

***Лямцев О.А.*[1,2],** ORCID 0009-0005-9487-5688
[1]ФГБНУ «Институт прикладной математики и механики», г. Донецк, РФ
[2]ФГБНУ «Институт проблем искусственного интеллекта», г. Донецк, РФ
gelo2003@yandex.ru

Введение. Оценка трёхмерной позы человека (3D Human Pose Estimation, 3D HPE) по монокулярным данным – ключевая задача компьютерного зрения. Она применяется в спортивной аналитике, телереабилитации, диагностике двигательных нарушений и человеко-машинном взаимодействии. Восстановление координат суставов обычными камерами открывает перспективы мониторинга активности вне лабораторий.

Несмотря на прогресс методов глубокого обучения, точность восстановления координат суставов снижается при окклюзиях – частичном или полном перекрытии частей тела. Окклюзии делят на самоокклюзию (конфигурацией позы), объектную (предметами сцены) и межличностную (другими людьми) [1].

Окклюзии порождают неоднозначность глубины, потерю информативных визуальных признаков и нарушение связей скелетной модели. Это увеличивает ошибку MPJPE, особенно для дистальных суставов [2]. Поэтому при анализе высокодинамичных и патологических движений робастность к окклюзиям критична, поскольку в этих условиях подходы демонстрируют наибольшую деградацию точности.

Цель работы – обзор и классификация методов повышения робастности монокулярной 3D HPE к окклюзиям, анализ их сильных и слабых сторон.

Условно можно выделить четыре основные группы методов повышения робастности к окклюзиям, не являющиеся взаимоисключающими.

Архитектурные подходы изменяют структуру нейронной сети для явного или неявного учёта отсутствующих суставов. Механизмы внимания с учётом окклюзий динамически перераспределяют внимание на видимые части тела с помощью специальных масок [3]. Графовые свёрточные сети с адаптивными связями моделируют скелет в виде графа и отключают либо перевзвешивают рёбра, соответствующие скрытым суставам. Модели на основе трансформеров корректируют механизм самовнимания через предсказанную карту видимости, а генерация множественных гипотез позволяет выбирать наиболее согласованный с видимыми частями вариант позы. Такие подходы, как правило, обеспечивают высокую устойчивость при частичных и средних окклюзиях, особенно когда имеется информация о видимости суставов. Вместе с тем они заметно увеличивают вычислительную сложность и часто оказываются чувствительными к качеству оценки видимости.

Подходы на уровне данных и обучения воздействуют на процесс обучения без принципиального изменения архитектуры [4]. Аугментация с учётом окклюзий искусственно создаёт перекрытия во время обучения, обучение с предсказанием видимости суставов заставляет сеть одновременно решать задачу классификации видимости и регрессии координат, а самообучаемые методы и методы без учителя, опирающиеся на временную согласованность, позволяют восстанавливать позу при длительных окклюзиях без дополнительной разметки. Обучение по учебному плану и отбор сложных примеров постепенно повышают сложность предъявляемых окклюзий. Эти методы относительно просты в реализации и почти не увеличивают время вывода. Однако их эффективность сильно зависит от реалистичности симуляции перекрытий, а при очень сильных и продолжительных окклюзиях они обычно уступают более сложным архитектурным решениям.

Пост-обработка и геометрические ограничения применяются уже после получения первичной оценки позы. Кинематические и скелетные априорные знания (постоянство длин костей, допустимые диапазоны углов) используются в модулях уточнения, временная согласованность на видеопоследовательностях сглаживает ошибки за счёт информации из соседних кадров [5], а специализированные модули уточнения на основе графов или трансформеров дорабатывают результат с учётом глобального контекста. Такие приёмы дают стабильный прирост точности практически без изменения базовой архитектуры модели и особенно полезны при работе с видео. Тем не менее они не способны полностью компенсировать

грубые ошибки первичной оценки в случае полной окклюзии крупных частей тела.

Гибридные и специальные стратегии сочетают элементы нескольких предыдущих групп либо используют узкоспециализированные приёмы. К ним относится подъём из 2D в 3D с учётом неопределённости, когда в сеть передаются не только координаты, но и оценки уверенности и карты окклюзий, а также модели с явным моделированием окклюзии, интегрирующие карты окклюзий или поля аффинности частей тела с учётом видимости непосредственно в процесс детекции. Гибридные решения, как правило, демонстрируют высокую робастность за счёт совместного использования информации о видимости, геометрических ограничений и временного контекста. Их главным недостатком остаётся более сложная реализация и настройка.

Заключение. Проведённый обзор показал, что повышение робастности монокулярной трёхмерной оценки позы человека к окклюзиям достигается различными взаимодополняющими стратегиями – от изменения архитектуры нейронных сетей и специальных процедур обучения до геометрических ограничений и гибридных схем. В целом более сложные архитектурные и гибридные подходы обеспечивают лучшую устойчивость к сильным окклюзиям, но требуют больше данных и вычислительных ресурсов. Методы, основанные преимущественно на аугментации, проще и быстрее, однако менее надёжны в экстремальных условиях. Существующие решения пока ограниченно проверены на патологических и высокодинамичных движениях в сочетании с реалистичными окклюзиями

Наиболее перспективными для задач анализа двигательной активности представляются гибридные методы, объединяющие предсказание видимости суставов, пространственно-временные модели и кинематические априорные ограничения. Именно такие подходы способны обеспечить необходимый уровень устойчивости в реальных условиях съёмки и могут служить основой для разработки робастных алгоритмов безмаркерной трёхмерной оценки позы человека.

Информация о финансовой поддержке: *Работа выполнена при финансовой поддержке Минобрнауки России в рамках научной темы «Разработка и совершенствование интеллектуальных методов классификации и прогнозирования для задач распознавания образов и моделирования информационных процессов» FREM-2024-0001 (Регистрационный номер 1023111000141-9-1.2.1)*

Список литературы

1. Guo, Y. A Survey of the State of the Art in Monocular 3D Human Pose Estimation: Methods, Benchmarks, and Challenges / Y. Guo, T. Gao, A. Dong [et al.] // Sensors. – 2025. – Vol. 25, № 8. – Art. 2409. – DOI 10.3390/s25082409.
2. Lino, F. Benchmarking 3D Human Pose Estimation Models under Occlusions / F. Lino, C. Santiago, M. Marques // arXiv. – 2025. – Текст: электронный. – URL: https://arxiv.org/abs/2504.10350 (дата обращения: 10.09.2026). – DOI 10.48550/arXiv.2504.10350.

3. Zheng, H. HiPART: Hierarchical Pose AutoRegressive Transformer for Occluded 3D Human Pose Estimation / H. Zheng, H. Li, W. Dai [et al.] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2025. – С. 16807–16817. – DOI 10.1109/CVPR52734.2025.01566.
4. Banik, S. Occlusion Robust 3D Human Pose Estimation with StridedPoseGraphFormer and Data Augmentation / S. Banik, P. Gschoßmann, A. M. García [et al.] // 2023 International Joint Conference on Neural Networks (IJCNN). – 2023. – С. 1–8. – DOI 10.1109/IJCNN54540.2023.10191355.
5. Roy, S. K. Occlusion Resilient 3D Human Pose Estimation / S. K. Roy, I. Badanin, S. Honari [et al.] // 2024 International Conference on 3D Vision (3DV). – 2024. – С. 1198–1207. – DOI 10.1109/3DV62453.2024.00099.

УДК 519.713.4

КОНТРОЛЬНЫЕ И РАСПОЗНАЮЩИЕ ЭКСПЕРИМЕНТЫ НА ПРОСТРАНСТВАХ ОБОБЩЕННЫХ АВТОМАТОВ

Максименко И.И., канд. физ.-мат. наук, ORCID 0009-0006-7269-5878
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
igor.maksimenko_1967@mail.ru

Введение. В теории управления дискретными системами фундаментальной задачей является идентификация исследуемого объекта, в качестве которого может выступать автомат, размеченный граф или иная конструктивно заданная структура, принадлежащая потенциально бесконечным классам. Для конечных классов автоматов Мили представителями научной школы И.С. Грунского были разработаны строгие критерии существования контрольных и распознающих экспериментов [1]. В то же время, для потенциально бесконечных классов аналогичные критерии остаются малоизученными.

В настоящей работе осуществлено обобщение отдельных положений монографии [1] на классы автоматов Мили, допускающие бесконечное число состояний. Такие классы могут быть интерпретированы как асинхронные автоматы Мили.

Актуальность настоящего подхода состоит в исследовании контрольных и распознающих экспериментов на метрических «бэровских» пространствах автоматов Мили с потенциально счетным числом состояний.

Целью данного исследования является получение критериев существования контрольных и распознающих экспериментов для обобщенных автоматов.

Основная часть. Приведем основные понятия и обозначения.

Не введенные здесь понятия берутся из работы [1].

Под обобщенным автоматом Мили будем понимать систему вида $A=(\mathrm{S},X,Y,\delta,\lambda,\mathrm{s}_0)$, где X – конечный алфавит входов, S,Y – счетные алфавиты состояний и выходов соответственно, $\delta\subseteq S\times X\times S$ – функция переходов, $\lambda\subseteq S\times X\times Y$ – функция выходов, $\mathrm{s}_0\in S$ -инициальное состояние.

Отметим, что конечные автоматы Мили и асинхронные автоматы являются обобщенными Мили.

Через $A(U)$ обозначим класс всех обобщенных всюду определенных, инициально связных, детерминированных автоматов Мили над внешним алфавитом $U=X\times Y$.

Алгоритм-экспериментатор называется контрольным экспериментом относительно априорно заданного потенциально бесконечного класса $F\subseteq A(U)$ и автомата-эталона $A\in A(U)$, если в результате проведения такого эксперимента с автоматом-«черным ящиком» из класса на выходе алгоритма получаем ответ, изоморфен «черный ящик» автомату-эталону или нет.

Иногда под контрольным экспериментом относительно класса $F\subseteq A(U)$ и автомата-эталона $A\in A(U)$ также понимают такое множество вход-выходных слов $W\subseteq L_A$, что если выполнено включение $W\subseteq L_B$ для некоторого автомата $B\in F$, тогда $A = B$. Под равенством $A = B$ далее понимаем изморфизм автоматов A и B.

Распознающим экспериментом для априорно заданного потенциально бесконечного класса $F\subseteq A(U)$ назовем такой алгоритм, который осуществляет эксперимент с «черным ящиком»-автоматом из нашего класса путем подачи входных символов и анализа выходных символов и выдает номер автомата $B\in F$ в фиксированной нумерации, которому изоморфен «черный ящик».

Класс $F\subseteq A(U)$ назовем финитно-распознаваемым, точно тогда, когда для класса существует некоторый распознающий эксперимент.

Множество всех вход-выходных слов автомата A длины не больше k обозначим через L_A^k.

Для исследования свойств экспериментов в классе автоматов $A(U)$ введем специальную «бэровскую» метрику β [2], полагая, что $\beta(A,B)=0$,если $A=B$ и $\beta(A,B)=\frac{1}{k}$, где $L_A^k\neq L_B^k$ и $L_A^{k-1}=L_B^{k-1}$.

Открытым шаром центром $A\in(A(U),\alpha)$ и радиусом $r\in R^+$ назовем множество $O_r(A)=\{B\mid\alpha(A,B)<r\}$.

Автомат $A\in(A(U),\alpha)$ назовем предельным автоматом класса $F\subseteq A(U)$, если для произвольного $r>0$ класс автоматов $O_r(A)\cap(F-\{A\})$ не пуст.

Для обобщенных автоматов Мили имеет место критерий существования контрольного эксперимента

Теорема 1. *Множество L_A^k для некоторого натурального числа k является контрольным экспериментом относительно класса $F\subseteq A(U)$ и*

автомата-эталона $A \in A(U)$ *точно тогда, когда автомат* A *не является предельным автоматом класса* F *в метрическом пространстве* $(A(U), \beta)$.

Для класса всех обобщенных автоматов Мили справедливо

Утверждение 2. *Для класса* $A(U)$ *и произвольного автомата-эталона* $A \in A(U)$ *в общем случае не существует контрольного эксперимента.*

Критерий финитной распознаваемости класса обобщенных автоматов дает следующая

Теорема 3. *Класс обобщенных автоматов* $F \subseteq A(U)$ *является финитно-распознаваемым точно тогда, когда для всякого автомата-эталона* $A \in A(U)$ *и класса* $F \subseteq A(U)$ *существует контрольный алгоритм-экспериментатор.*

Из теоремы 3 вытекает

Следствие 4. *Справедливы утверждения:*

1. Финитно-распознаваемый класс $F \subseteq A(U)$ *является открытым в метрическом пространстве* $(A(U), \beta)$.

2. Произвольный конечный класс автоматов $F \subseteq A(U)$ *всегда финитно-распознаваем.*

3. Финитно-распознаваемый класс $F \subseteq A(U)$ *не является рекурсивным классом в общем случае, но всегда пополняем до рекурсивно перечислимого финитно-распознаваемого класса.*

Заключение. В настоящей работе математический аппарат построения контрольных экспериментов распространён на потенциально бесконечные классы обобщённых автоматов Мили с сохранением основного критерия существования контрольных экспериментов [2,3,4].

Также в работе сформулирована теорема о каноническом представлении распознающего эксперимента в терминах рекурсивно перечислимого множества контрольных экспериментов, что является прямым обобщением критерия финитной распознаваемости классов конечных автоматов Мили [1] на более широкий класс автоматов.

В будущем автор планирует перенос элементов теории экспериментов к анализу и верификации нейросетевых архитектур [5].

Список литературы

1. Грунский, И. С. Синтез и идентификация автоматов / И. С. Грунский, В. А. Козловский. – Киев: Наук. думка, 2004. – 245 с.
2. Максименко, И. И. Алгебраические представления в «бэровских» пространствах / И. И. Максименко // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2023. – № 4. – С. 54-64. – EDN YBTKIO.
3. Максименко, И. И. Алгебраическая и топологическая представимость решеток / И. И. Максименко // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2024. – № 2. – С. 44-50. – EDN RRMOKS.
4. Максименко, И. И. Представимость классов автоматов Мили в терминах бэровских и р-адических метрик / И. И. Максименко // Вестник Донецкого национального

университета. Серия Г: Технические науки. – 2025. – № 2. – С. 118-124. – EDN BMIUQR.
5. Максименко, И. И. Контрольные эксперименты с автоматами в бэровских и р-адических метриках / И. И. Максименко // Донецкие чтения – 2025: образование, наука, инновации, культура и вызовы современности: Материалы X Международной научной конференции, посвященной 60-летию создания Донецкого научного центра, Донецк, 05–07 ноября 2025 года. – Донецк: Донецкий государственный университет, 2025. – С. 381-383. – EDN KASZCX.

УДК 004.8

АГЕНТНЫЙ ПОДХОД К ПОСТРОЕНИЮ ИНТЕЛЛЕКТУАЛЬНОГО АССИСТЕНТА РАЗРАБОТЧИКА ДЛЯ КОНФИГУРАЦИЙ 1С:ПРЕДПРИЯТИЕ

Максименко И.И., 0009-0006-7269-5878,
Богданов Н.А., 0009-0002-2011-9722
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
igor.maksimenko_1967@mail.ru, do.flamin@mail.ru

Введение. Платформа «1С:Предприятие» остаётся основным средством автоматизации учёта в российских организациях. Прикладные конфигурации на её основе насчитывают тысячи объектов метаданных и сотни тысяч строк кода на встроенном языке, причём каждая конфигурация индивидуальна: типовые решения дорабатываются под конкретное предприятие. Поэтому знание «типовой» конфигурации не позволяет ответить на вопрос, как устроен конкретный механизм в конкретной базе. Разработчику приходится вручную прослеживать цепочки вызовов.

Большие языковые модели (LLM) хорошо генерируют код, но без доступа к конкретной конфигурации отвечают по обобщённым представлениям и склонны к галлюцинациям – уверенному изложению несуществующих реквизитов и методов [1]. Такой ответ опаснее отсутствия его отсутствия.

Актуальность исследования определяется потребностью в инструменте, который отвечает на вопросы о конкретной конфигурации 1С и генерирует код с учётом её метаданных, не требуя переобучения модели при смене или изменении конфигурации. Дообучение (fine-tuning) под каждую конфигурацию требует больших затрат, должно повторяться после каждого изменения кода и уступает подходам с извлечением знаний при внедрении в модель новых фактов [2].

Целью исследования является разработка и экспериментальная проверка архитектуры ассистента разработчика 1С, который самостоятельно исследует конфигурацию с помощью программных инструментов и отвечает только на основе фактически прочитанного кода.

Основная часть. Классический способ подключения внешних знаний к модели – генерация, дополненная извлечением (RAG) [3]: корпус заранее индексируется, и в контекст модели подставляются фрагменты, наиболее похожие на вопрос. Для программного кода подход развит в работах по дополнению кода на уровне репозитория [4]. На первом этапе работы был реализован такой вариант: выгрузка конфигурации разбиралась в реляционную базу данных, строились полнотекстовый индекс и граф вызовов. Эксперименты выявили два ограничения: извлечение по текстовому сходству плохо находит логику, распределённую по нескольким модулям, а предварительный разбор всех объектов крупной конфигурации оказался длительным и чувствительным к особенностям формата выгрузки.

Поэтому в работе принят агентный подход, основанный на схеме ReAct [5], в которой модель чередует рассуждение и действие: она сама определяет, какие данные ей нужны, запрашивает их через инструменты и продолжает рассуждение на основе полученного результата. Сходный принцип используется в агентах для разработки программного обеспечения, где качество работы во многом определяется интерфейсом инструментов [6].

Разработанная система включает следующие компоненты:

1) Лёгкий индексатор. По структуре каталогов выгрузки конфигурации в файлы [7] строится каталог объектов, модулей и методов с указанием их расположения. Код и метаданные в индекс не копируются, поэтому индексация крупной конфигурации занимает секунды, а смена конфигурации сводится к повторному запуску индексатора.

2) Инструменты исследования конфигурации: поиск функциональности по ключевым словам с учётом словоизменения, чтение кода метода, список вызовов из метода с указанием места определения каждого вызываемого метода, обратный поиск вызывающих методов, чтение метаданных объекта (разбираются по требованию – только для запрошенного объекта).

3) Цикл агента, ведущий трассировку обращений (пользователь видит, на основе какого кода сделан вывод), и слой провайдеров, позволяющий подключать облачные модели, в том числе доступную в России GigaChat [8], и локально развёрнутые модели.

В ходе экспериментов на реальной конфигурации выявлены проблемы, для которых предложены следующие решения:

1) Имитация вызова инструментов. Модель без устойчивой поддержки вызова функций записывала обращения к инструментам в виде текста и сама сочиняла их результаты: в одном из прогонов ответ содержал правдоподобный код метода проведения при нуле фактических обращений к конфигурации. Реализованы детектор имитации и резервный текстовый протокол: из ответа извлекается только первый вызов, он выполняется фактически, а сочинённая часть заменяется реальным результатом.

2) Уход исследования в сторону. Без ориентира модель погружалась в универсальный механизм проведения документов: в одном из прогонов 19 обращений к инструментам не затронули предметную область вопроса. Решением стал автоматический первичный поиск по ключевым словам вопроса: модель сразу получает ранжированный список объектов и методов, где встречается искомая функциональность. На тестовой конфигурации это позволило дойти до кода, выполняющего запись движений в регистр, за четыре обращения к инструментам.

3) Зацикливание: при повторении одних и тех же вызовов ответ формируется по уже собранным данным.

4) Несоответствие нотации: модель обращается к объектам по-русски («Документ.…»), а в выгрузке используются английские имена типов; добавлена нормализация имён.

Заключение. Разработан прототип агентного ассистента для конфигураций 1С:Предприятие, не требующий дообучения модели и переключаемый на другую конфигурацию повторной индексацией. Эксперименты показали, что надёжность агента определяется не только языковой моделью, но и интерфейсом инструментов, первичной навигацией по конфигурации и программным контролем достоверности ответов. Дальнейшая работа – количественное сравнение агентного подхода с классическим RAG и разных моделей по доле обоснованных ответов, числу галлюцинаций и времени ответа.

Список литературы

1. Ji Z. Survey of Hallucination in Natural Language Generation / Z. Ji, N. Lee, R. Frieske [et al.] // ACM Computing Surveys. – 2023. – Vol. 55, No. 12. – Art. 248.
2. Ovadia O. Fine-Tuning or Retrieval? Comparing Knowledge Injection in LLMs / O. Ovadia, M. Brief, M. Mishaeli [et al.] // Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing. – Miami: ACL, 2024. – P. 237–250.
3. Lewis P. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks / P. Lewis, E. Perez, A. Piktus [et al.] // Advances in Neural Information Processing Systems. – 2020. – Vol. 33. – P. 9459–9474.
4. Zhang F. RepoCoder: Repository-Level Code Completion Through Iterative Retrieval and Generation / F. Zhang, B. Chen, Y. Zhang [et al.] // Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. – Singapore: ACL, 2023. – P. 2471–2484.
5. Yao S. ReAct: Synergizing Reasoning and Acting in Language Models / S. Yao, J. Zhao, D. Yu [et al.] // International Conference on Learning Representations (ICLR). – 2023. – arXiv:2210.03629.
6. Yang J. SWE-agent: Agent-Computer Interfaces Enable Automated Software Engineering / J. Yang, C. E. Jimenez, A. Wettig [et al.] // Advances in Neural Information Processing Systems. – 2024. – Vol. 37. – P. 50528–50652.
7. 1С:Предприятие 8.3.26. Руководство разработчика. Глава 2. Работа с конфигурацией [Электронный ресурс]. – URL: https://its.1c.ru/db/v8326doc/bookmark/dev/TI000000044 (дата обращения: 19.09.2026).
8. GigaChat API. Работа с функциями [Электронный ресурс]. – URL: https://developers.sber.ru/docs/ru/gigachat/guides/main (дата обращения: 19.09.2026).

УДК 004.8

ИСПОЛЬЗОВАНИЕ ГЛУБОКОГО ОБУЧЕНИЯ НЕЙРОСЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ И ВОСПРОИЗВЕДЕНИЯ МУЗЫКАЛЬНЫХ ПРОИЗВЕДЕНИЙ

Максименко И.И., 0009-0006-7269-5878, ***Маликов В.А.***
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
daleman303@vk.com, igor.maksimenko_1967@mail.ru

Введение. Современные стриминговые сервисы (Spotify, Apple Music, Яндекс.Музыка) активно используют технологии машинного обучения как для каталогизации контента, так и для персонализации рекомендаций. Классификация музыкальных жанров наряду с традиционными подходами, основанными на метаданных и пользовательских тегах, все чаще требует применения методов глубокого обучения для анализа непосредственно аудиосигнала. Это необходимо для задач автоматического плейлистинга, обнаружения семантического сходства треков и построения рекомендательных систем. Однако многие исследования ограничиваются этапом классификации, не предлагая удобного способа использования результатов в реальном пользовательском сценарии.

Актуальность работы заключается в необходимости повышения точности методов автоматической классификации музыкальных жанров и их интеграции в прототип приложения с модулем воспроизведения. Разработка компактных и эффективных гибридных моделей, способных не только точно классифицировать жанры, но и быть интегрированными в легковесные приложения, является актуальной задачей в области Music Information Retrieval (MIR).

Целью данного исследования является разработка и программная реализация приложения для классификации и воспроизведения музыкальных композиций, основанного на гибридной нейросетевой модели анализа спектральных представлений аудиосигнала.

Основная часть. Музыкальный аудиосигнал представляет собой сложный, многокомпонентный временной ряд, обладающий полифонической природой, иерархической временной структурой и высокой вариативностью внутри одного жанра. Основные проблемы автоматической классификации включают отсутствие четких границ между жанрами, зависимость от качества записи и высокую размерность данных. Для решения этих проблем используются два ключевых этапа: преобразование сырого аудиосигнала в компактное информативное представление и применение моделей глубокого обучения.

В качестве входных представлений в работе рассматриваются мел-спектрограммы, мел-частотные кепстральные коэффициенты (MFCC), хромаграммы и спектральные контрастности. Для повышения робастности

модели применяются методы аугментации аудиоданных: изменение высоты тона (pitch shift), изменение темпа (time stretch), добавление шума (noise injection) и спектральные маскировки (SpecAugment).

Анализ архитектур глубокого обучения показал, что сверточные нейронные сети (CNN) эффективны для выделения локальных спектрально-временных паттернов, рекуррентные сети (LSTM, GRU) – для моделирования временной динамики, а механизмы внимания и Transformer-архитектуры позволяют улавливать глобальные структуры композиции. Гибридные модели (CNN + LSTM, CNN + Attention) позволяют достичь более высокой точности, чем каждая из архитектур по отдельности. Также рассмотрены предобученные модели VGGish, YAMNet и MusiCNN, которые могут использоваться как готовые экстракторы признаков или дообучаться под конкретную задачу.

Научная новизна работы заключается в разработке гибридной архитектуры нейронной сети для классификации музыкальных жанров, отличающейся от известных решений комбинацией многомасштабного анализа мел-спектрограмм с помощью модифицированных residual-блоков с расширяющимися свертками (dilated convolutions) и последующего взвешивания временных признаков с использованием механизма кросс-внимания (cross-attention). Это позволяет повысить точность классификации на датасетах с высокой вариативностью внутрижанровых признаков без пропорционального увеличения числа обучаемых параметров.

Практическая значимость результатов состоит в разработке программного обеспечения (прототипа приложения), реализующего алгоритмы нейросетевой классификации музыкальных жанров и модуль воспроизведения с логикой формирования плейлистов. Это позволит автоматизировать каталогизацию крупных музыкальных архивов и радиостанций, создать основу для образовательных инструментов по изучению музыкальных жанров, реализовать модуль «умного» перемешивания плейлистов в существующих стриминговых сервисах и снизить временные затраты на ручную разметку музыкальных коллекций.

Заключение. В данном исследовании проведен системный анализ современных методов представления аудиоданных и архитектур глубокого обучения в контексте задачи классификации музыкальных жанров. Разработан эффективный пайплайн предобработки и аугментации аудиоданных на основе открытых датасетов GTZAN и FMA. Спроектирована гибридная архитектура нейронной сети, сочетающая многомасштабные сверточные блоки на основе residual-соединений и механизм временного внимания. Реализованы модели и алгоритмы классификации с использованием фреймворка PyTorch, проведен их сравнительный анализ с базовыми архитектурами (VGG-like CNN) и предобученными моделями (VGGish). Разработана архитектура клиент-серверного приложения (backend на FastAPI, frontend на HTML/CSS/JavaScript), интегрирующего

обученную модель и модуль воспроизведения. Результаты показывают, что предложенная гибридная модель является перспективным решением для повышения точности классификации музыкальных жанров и может быть эффективно интегрирована в приложения с функцией воспроизведения.

Список литературы

1. Маликов В. А. Разработка приложения классификации и воспроизведения музыкальных мелодий различных жанров на основе глубокого обучения: выпускная квалификационная работа / В. А. Маликов. – Донецк: ДонГУ, 2026.
2. Рупак М. Модели глубокого обучения для обеспечения кибербезопасности в сетях Интернета вещей / М. Рупак, Г. Юн Тянь, Дж. Чемберс // IEEE, 9-й ежегодник. Вычислительная техника. Сообщество. Конференция-практикум (CCWC), январь 2019. – С. 0452–0457.
3. Аслан Ö. Новая система классификации вредоносных программ, основанная на алгоритмах глубокого обучения / Ö. Аслан, А. А. Йилмаз // IEEE Access. – 2021. – Т. 9. – С. 87936–87951.
4. Гулли А. Глубокое обучение с помощью Keras / А. Гулли, С. Пэл. – Мумбаи, Индия: Packt Publishing Ltd, 2017.
5. Берман Д. Обзор методов глубокого обучения для обеспечения кибербезопасности / Д. Берман, А. Бучак, Дж. Чавис и др. // Информация. – 2019. – Т. 10, № 4. – С. 122.

УДК 004.896

НЕЙРОСИМВОЛЬНЫЙ МОНИТОРИНГ СОБЛЮДЕНИЯ ПРОМЫШЛЕННЫХ РЕГЛАМЕНТОВ ПО ВИДЕОПОТОКУ

***Максимова А.Ю.*[1],** канд. техн. наук, ORCID 0000-0001-9496-4385,
***Лямцев О.А.*[1,2],** ORCID 0009-0005-9487-5688,
***Чернядьев И.В.*[1,2],** ORCID 0009-0008-6557-1601
[1]ФГБНУ «Институт прикладной математики и механики», г. Донецк, РФ
[2]ФГБНУ «Институт проблем искусственного интеллекта», г. Донецк, РФ
maximova.alexandra@mail.ru, gelo2003@yandex.ru, chernyadev-i@mail.ru

Введение. Промышленные процессы включают повторяющиеся операции, которые должны строго выполняться в соответствии со стандартной операционной процедурой (SOP). Нарушение регламентов приводит к снижению качества продукции и эффективности производства, что делает автоматический контроль соблюдения SOP актуальной и практически значимой задачей. Несмотря на широкое использование систем видеонаблюдения, ручной контроль остаётся неэффективным, а современные модели распознавания действий требуют больших объёмов разметки, плохо интерпретируемы и сложно адаптируются к изменению технологических регламентов.

Целью является разработка интерпретируемой гибридной нейросимвольной системы мониторинга соблюдения промышленных регламентов по видеопотоку, разделяющей визуальное восприятие и принятие решений на основе логических правил, что позволяет устранить описанные выше недостатки существующих подходов.

Основная часть. Рассматривается задача автоматического мониторинга соблюдения SOP работником в видеопотоке с камеры. Входные данные представлены последовательностью кадров $V = \{I_t\}_{t=1}^{T}$, где $I_t \in R^{H \times W \times 3}$ – RGB-изображение в момент времени *t*, *H* и *W* – высота и ширина кадра, T – число обрабатываемых кадров.

Требуется построить отображение (1):

$$F: V \to \left(\{e_t^i\}_{i=1}^{k_t}\right)_{t=1}^{T} \quad (1)$$

где e_t^i – целевое событие, k_t – число событий в момент времени t.

При такой постановке, предлагается **гибридный подход**, объединяющий нейросетевой модуль (визуальное восприятие с помощью детекции и трекинга объектов) и модуль логического вывода (семантическая интерпретация и принятие решений). Предложенный подход был протестирован на примере мониторинга действий работников на молочной ферме при доении коров в доильном зале карусельного типа.

Нейросетевой модуль для каждого кадра I_t создает множество детектируемых объектов, а трекер связывает детекцию между последовательными кадрами и назначает идентификатор каждому объекту, пока он остается видимым на сцене, согласно (2):

$$D_t = \{d_t^i\}_{i=1}^{n_t} \quad (2)$$

где $d_t^i = \left(b_t^i, c_t^i, q_t^i, s_t^i\right)$ – каждая детекция, $b_t^i = \left(x_t^i, y_t^i, w_t^i, h_t^i\right)$ – ограничивающая рамка объекта, $c_t^i \in \mathcal{C}$ – класс объекта, $\mathcal{C} = c_1, c_2, \dots, c_m$ – множество классов, необходимых для анализа, $q_t^i \in \mathbb{N}$ – ID объекта, $s_t^i \in [0,1]$ – степень уверенности.

При этом подход не ограничивается конкретным алгоритмом детекции или отслеживания, что позволяет заменить нейросетевой модуль без изменения логического модуля. В своей реализации мы использовали детектор YOLO11n [1] и трекер ByteTrack [2].

Логический модуль. На основе текстового описания SOP вручную формируется список целевых классов объектов $\mathcal{C} = c_1, c_2, \dots, c_m$. Логический вывод реализован на миварном подходе [3]: каждое продукционное правило активируется при наличии значений всех входных параметров и формирует значение выходного параметра. Процесс продолжается до получения целевого события $E = \{e_i\}_{i=1}^{n_t}$.

База шаблонов логических правил $P = (R, \Theta)$, где R – набор правил, которые могут содержать проверки пространственных отношений («пересечение», «касание» и др.), Θ – числовые модификаторы правил (время, расстояние). В таблице показа часть базы знаний *P*, где *x* – входные параметры, *y* – выходные параметры.

Таблица

Часть базы знаний

hand	hand x	hand y	foam	foam x	foam y	state1	state2	event1
x	x	x				y		
			x	x	x	x	y	
						x	x	y

Для каждого кадра правила дополняются идентификаторами обнаруженных объектов, дублируются в соответствии с количеством объектов каждого класса и дополняются правилами предыдущих шагов. Целевое событие генерируется при завершении операции или выходе объекта из зоны наблюдения и содержит интерпретируемый результат оценки действия. Важным преимуществом является возможность автоматизации процедуры наполнения базы знаний, а также возможность повторного использования и адаптации шаблонов правил под новые регламенты.

Экспериментальная оценка. Система протестирована на задаче мониторинга действий операторов на молочной ферме, включающей три рабочие станции. Для каждой станции обучена отдельная модель YOLO11n.

Среднее время обработки кадра составляет 10 мс при FPS 24, что обеспечивает работу в реальном времени.

Качество детекции объектов характеризуется значениями mAP50 / mAP50-95: 0.922 / 0.713 (станция 1), 0.846 / 0.603 (станция 2) и 0.915 / 0.680 (станция 3).

Точность всей гибридной системы по F1-score достигает 0.998, 0.999 и 0.972 на станциях 1-3 соответственно.

Полученные результаты подтверждают высокую эффективность предложенного подхода и возможность его практического применения в промышленных условиях.

Заключение. Предложенный гибридный нейросимвольный подход обладает рядом преимуществ: не требует покадровой и на уровне действий разметки, обеспечивает интерпретируемость решений за счёт логических правил и позволяет быстро адаптировать систему к изменению регламентов без переобучения нейросети. Разделение визуального восприятия и семантического принятия решений обеспечивает работу в реальном времени и устойчивость к ошибкам детекции. Таким образом, система сочетает надёжность нейросетевой детекции объектов с прозрачностью логического вывода, генерируя интерпретируемые события о соблюдении или нарушении технологических регламентов.

Информация о финансовой поддержке*: Работа выполнена при финансовой поддержке Минобрнауки России в рамках научной темы «Разработка и совершенствование интеллектуальных методов классификации и прогнозирования для задач распознавания образов и моделирования информационных процессов» FREM-2024-0001 (Регистрационный номер 1023111000141-9-1.2.1)*

Список литературы

1. 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 (CVPR). – 2016. – P. 779–788. – DOI: 10.1109/CVPR.2016.91.
2. Zhang, Y. ByteTrack: Multi-Object Tracking by Associating Every Detection Box / Y. Zhang, P. Sun, Y. Jiang [et al.] // Computer Vision – ECCV 2022: 17th European Conference on Computer Vision, Tel Aviv, Israel, October 23–27, 2022, Proceedings. Part XXII. – Cham: Springer, 2022. – P. 1–21. – DOI: 10.1007/978-3-031-20047-2_1.
3. Varlamov, O. Mivar: Transition from Productions to Bipartite Graphs Mivar Nets and Practical Realization of Automated Constructor of Algorithms Handling More than Three Million Production Rules / O. Varlamov. – 2011. – URL: https://arxiv.org/abs/1111.1321 (дата обращения: 11.06.2026).

УДК 004.8

ПОСТРОЕНИЕ МОДЕЛЕЙ ДЕТЕКТОРОВ ГАЛЛЮЦИНАЦИЙ В ОТВЕТАХ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ

***Манха О.А.*[1,2]**, ORCID 0009-0005-1510-1466,
***Блохин С.В.*[2]**, ORCID 0009-0002-8330-0123,
***Елисеев В.О.*[1]**, ORCID 0009-0006-5941-2968,
***Максимова А.Ю.*[1]**, ORCID 0000-0001-9496-4385,
***Дидур Д.А.*[1,2]**, ORCID 0009-0006-4283-2587
[1]ФГБНУ «Институт прикладной математики и механики», г. Донецк, РФ
[2]ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
olegmanha@yandex.ru, *bsvtsu@mail.ru, eliseevv02@mail.ru, maximova.alexandra@mail.ru, deana.didur@yandex.ru*

Введение. В последние годы большие языковые модели (БЯМ) получили широкое распространение в задачах обработки естественного языка [1]. Однако фундаментальной проблемой их применения являются галлюцинации – правдоподобные, но фактически неверные или не соответствующие запросу или контексту ответы модели [1, 2]. Подобные ошибки ограничивают использование БЯМ в критических областях, чувствительных к достоверным ответам (медицина, финансы, право и т. д.).

Основная часть. В данной работе решалась задача автоматического обнаружения галлюцинаций. Галлюцинацией считается ответ, не соответствующий истинному или допустимому результату либо отклоняющийся от исходного контекста [3]. Требуется построить модель, определяющую наличие галлюцинации в ответе БЯМ (класс 1) или её отсутствие (класс 0).

Для обучения и оценки такой модели необходимо использовать размеченные текстовые данные, содержащие как корректные ответы, так и

ответы с галлюцинациями. Наличие меток классов позволяет применять методы обучения с учителем и оценивать способность алгоритмов выявлять недостоверные ответы.

Для решения задачи использовался открытый набор данных [4] содержащий тройки: запрос к БЯМ, ответ модели (в данном случае использовалась Mistral-7B-Instruct) и метку, обозначающую содержит ли ответ модели галлюцинации.

Данные были разделены на обучающую и тестовую выборки в соотношении 90/10. Для обеспечения корректного сравнения моделей применялась стратифицированная (сохраняющая соотношение классов в каждом блоке) кросс-валидация с разбиением на 5 блоков. На рисунке представлено соотношение классов в выбранном наборе данных.

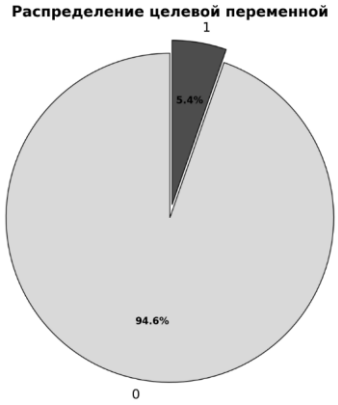


Рис. Распределение классов в наборе данных

Были проведены эксперименты с классическими алгоритмами машинного обучения, нейронными сетями и дообучением БЯМ. Среди классических алгоритмов использовались RandomForest – ансамбль решающих деревьев и LightGBM – градиентный бустинг, последовательно исправляющий ошибки предыдущих деревьев. Для векторизации текстов применялся TF-IDF, формирующий разреженные векторные представления. Среди нейросетевых подходов исследовались двусторонняя RNN, учитывающая контекст в обоих направлениях; LSTM, способная обрабатывать долгосрочные зависимости; CNN, выявляющая локальные закономерности в последовательностях токенов; а также CNN с предобученными эмбеддингами GloVe для учета семантики слов. В качестве дообучаемых БЯМ применялись GPT-2 – трансформерная модель с механизмом внимания у которой выходной линейный слой был заменен на слой с двумя выходами, соответствующими классам наличия и отсутствия галлюцинации, и GPT-Neo – более масштабная трансформерная модель, адаптированная для классификации текста. Дообучение обеих моделей проводилось в течение одной эпохи с использованием графического процессора Apple M2.

В таблице представлены метрики качества обученных моделей. В качестве основной была выбрана ROC AUC (площадь под ROC (Receiver

Operating Characteristic) кривой), поскольку метрика устойчивая к дисбалансу классов, который явно наблюдается в решаемой задаче. Кроме того, данная метрика показывает, насколько хорошо модель умеет ранжировать объекты вне зависимости от выбранного порога, использование которого необходимо при практическом применении обученного детектора.

Расчет значений метрик осуществлялся с применением стратифицированной кросс-валидации с разбиением на 5 блоков, при этом итоговое значение каждой метрики определялось как среднее по всем разбиениям.

Таблица

Метрики качества обученных моделей

	ROC-AUC	**Accuracy**
LightGBM	0.803	0.948
RandomForest	0.775	**0.949**
RNN	0.658	0.926
CNN	0.761	0.934
LSTM	0.693	0.931
CNN with GloVe	0.694	0.924
GPT-2	0.874	0.947
GPT-Neo 125M	**0.888**	0.948

Заключение. Проведено сравнительное исследование классических алгоритмов машинного обучения, нейронных сетей и дообученных БЯМ для автоматического обнаружения галлюцинаций. Лучшее качество продемонстрировала дообученная GPT-Neo 125M, обойдя алгоритмы, не связанные с БЯМ практически на 0.1. Однако стоит помнить, что вычислительные затраты БЯМ ограничивают их применение в реальном времени, требуя баланса между качеством и скоростью.

Информация о финансовой поддержке: *Работа выполнена при финансовой поддержке Минобрнауки России в рамках научной темы «Разработка и совершенствование интеллектуальных методов классификации и прогнозирования для задач распознавания образов и моделирования информационных процессов» FREM-2024-0001 (регистрационный номер 1023111000141-9-1.2.1).*

Список литературы

1. Huang L. A Survey on Hallucination in Large Language Models: Principles, Taxonomy, Challenges, and Open Questions / L. Huang, W. Yu, W. Ma [et al.] // ACM Transactions on Information Systems. – 2025. – Vol. 43, No. 2. – Art. 42. – P. 1–55. – DOI 10.1145/3703155.
2. Kalai A. T. Why Language Models Hallucinate / A. T. Kalai, O. Nachum, S. S. Vempala [et al.]. – 2025. – Текст: электронный. – arXiv:2509.04664. – URL: https://arxiv.org/abs/2509.04664 (дата обращения: 04.10.2026).
3. Maleki N. AI Hallucinations: A Misnomer Worth Clarifying / N. Maleki, B. Padmanabhan, K. Dutta // 2024 IEEE Conference on Artificial Intelligence (CAI). – IEEE, 2024. – P. 133–138. – DOI 10.1109/CAI59869.2024.00033.
4. Eliseev V. Hallucination Detection / V. Eliseev. // GitHub. – Текст: электронный – URL: https://github.com/EliseevVadim/hallucinations-detection (дата обращения: 04.10.2026).

УДК 004.4

РАЗРАБОТКА АВТОМАТИЗИРОВАННОЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ УЧЁТА И АНАЛИЗА ДЕЯТЕЛЬНОСТИ КОСМЕТОЛОГИЧЕСКОЙ КЛИНИКИ

Мартыненко А-А.М., ORCID 0009-0006-5009-8773, ***Свинцицкая О.С.***
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
a.martinenko@donnu.ru, olga.svintsitskaya.04@bk.ru

Введение. Работа косметологической клиники связана с обработкой большого объёма информации о клиентах, услугах, сотрудниках, расписании и проведённых визитах. Использование разрозненных таблиц и записей затрудняет поиск и обновление данных, контроль занятости специалистов и получение сводной информации о деятельности организации.

Для автоматизации подобных процессов применяются различные программные решения, в том числе YCLIENTS, 1С:Салон красоты, SalonSoft и Salonist. Облачные системы предоставляют широкий набор функций, однако требуют подключения к Интернету и, как правило, предусматривают абонентскую плату. Некоторые локальные продукты, напротив, имеют избыточный для небольшой клиники функционал [1–3]. Поэтому актуальной является разработка локальной информационной системы, ориентированной на основные задачи косметологической клиники.

Цель работы – разработка автоматизированной информационной системы «ЭстетикПро» для учёта клиентов, услуг, сотрудников, регистрации записи на приём, истории визитов, а также анализа доходности клиники.

Основная часть. Согласно проведенному глубокому анализу предметной области, были выделены бизнес-процессы и определен основной функционал, требуемый программной реализации. Анализ существующих решений показал, что зачастую для организации работы используются облачные системы. Однако такая работа зависят от наличия Интернет-соединения. Локальные решения обеспечивают больший контроль над хранением информации и могут быть адаптированы под конкретные задачи. В связи с этим для разработки было выбрано локальное настольное приложение.

Пользовательский интерфейс приложения должен быть удобным и интуитивно понятным. Функционал программы должен включать в себя все требуемые группы пользователей (клиенты, администраторы, специалисты), а его использование должно достигать все бизнес-цели клиники.

Программа разработана на языке C# с использованием Windows Forms и платформы .NET 6.0 в среде Microsoft Visual Studio [4, 5]. При проектировании применён объектно-ориентированный подход.

В системе реализовано шесть основных объектов: Client, Service, Employee, Appointment, VisitHistory и FileStorage – компонент хранения данных.

Объект Appointment связывает клиента, выбранную услугу и сотрудника и содержит дату, время и статус приёма. Основные взаимосвязи между объектами представлены на UML-диаграмме классов (рис. 1).

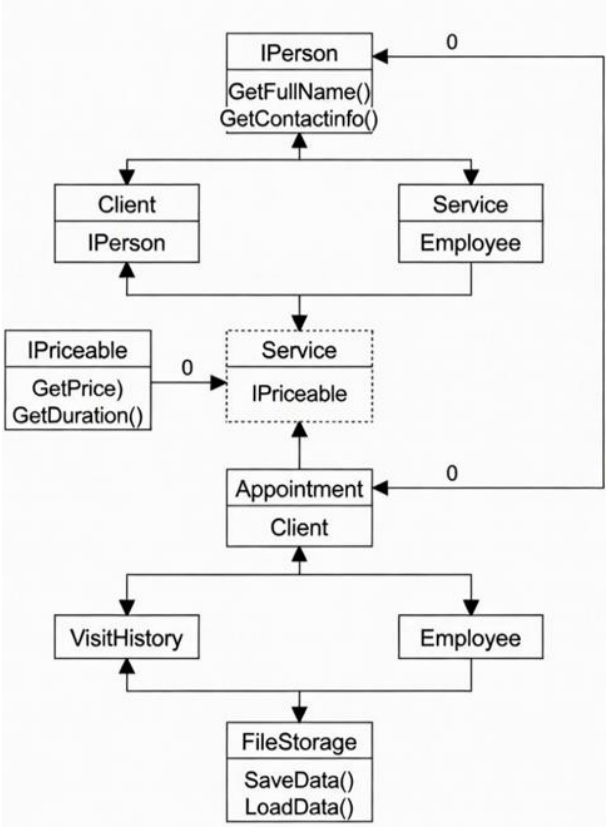


Рис. 1. UML-диаграмма классов приложения

При создании записи выполняется проверка занятости сотрудника, что позволяет предотвратить одновременное назначение двух приёмов одному специалисту. Если обнаруживается пересечение, сохранение блокируется.

Администратор может добавлять, редактировать и удалять сведения о клиентах, услугах и сотрудниках, а также создавать и изменять записи на приём.

При создании записи ей присваивается статус «Запланировано». После завершения приёма статус изменяется на «Завершено», а сведения автоматически добавляются в историю визитов. При этом обновляются количество посещений клиента и сумма его расходов. В случае отмены приёма устанавливается статус «Отменено».

Для хранения информации используется формат JSON. Компонент **FileStorage** выполняет загрузку данных при запуске приложения и их сохранение после внесения изменений [6]. Структура данных представлена на рисунке 2.



Рис. 2. Структура данных информационной системы «ЭстетикПро»

Заключение. В результате работы получено программное обеспечение, предназначенное для автоматизации основных процессов учёта в косметологической клинике. Система обеспечивает работу со сведениями о клиентах, услугах, сотрудниках и записях на приём, а также позволяет формировать историю визитов и получать данные о выручке.

Функциональное тестирование подтвердило работоспособность разработанных возможностей. В дальнейшем систему можно расширить за счёт более подробной аналитики, дополнительных отчётов и перехода к централизованной базе данных для организации многопользовательской работы.

Список литературы

1. Microsoft Corporation. Документация по .NET [Электронный ресурс]. – URL: https://docs.microsoft.com/ru-ru/dotnet/ (дата обращения: 20.04.2026).
2. Microsoft Corporation. Документация по Windows Forms [Электронный ресурс]. – URL: https://docs.microsoft.com/ru-ru/dotnet/desktop/winforms/ (дата обращения: 20.04.2026).
3. Троелсен, Э. Язык программирования C# 9.0 и платформа .NET 5.0 / Э. Троелсен, Ф. Джепикс. – М.: Вильямс, 2021. – 1344 с. – ISBN 978-5-907203-61-4.
4. Шилдт, Г. C# 7.0: Полное руководство / Г. Шилдт. – М.: Вильямс, 2020. – 1056 с. – ISBN 978-5-8459-2087-4.
5. Агишев, Р. Р. Разработка приложений на C# с использованием Windows Forms / Р. Р. Агишев. – М.: ДМК Пресс, 2020. – 312 с. – ISBN 978-5-97060-839-4.
6. JSON. Официальная документация [Электронный ресурс]. – URL: https://www.json.org/json-ru.html (дата обращения: 20.04.2026).
7. Бондаренко, Е. В. Объектно-ориентированное программирование на C# / Е. В. Бондаренко. – М.: Юрайт, 2021. – 284 с. – ISBN 978-5-534-14830-9.

УДК 004.42:004.8

ТИПИЗИРОВАННЫЙ ПРОТОКОЛ СООБЩЕНИЙ КАК СПОСОБ ОБЕСПЕЧЕНИЯ НЕЗАВИСИМОСТИ КОМПОНЕНТОВ ИНТЕРАКТИВНОЙ СИСТЕМЫ

Мартыненко А-А.М., ORCID 0009-0006-5009-8773, ***Тукмачев С.А.,***
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
a.martinenko@donnu.ru, serg.tukmachev2006@mail.ru

Введение. Современные интерактивные системы всё чаще состоят из нескольких компонентов, которые работают как отдельные процессы и обмениваются данными по сети. Такие компоненты удобно разрабатывать независимо, в том числе разными людьми и на разных языках программирования. Проблема возникает тогда, когда формат обмена между этими модулями не имеет чёткой структуры. Например, изменение одного компонента способно незаметно «сломать» работу другого, а код разбора входящих сообщений оказывается «размазан» по разным местам программы.

Целью работы является описание способа построения обмена сообщениями между независимыми компонентами системы, который снимает эту проблему за счёт единого типизированного формата.

Основная часть. Идея заключается в том, чтобы каждое сообщение между компонентами системы имело одинаковую структуру: тип события и данные, которые к этому типу относятся. Например, если один компонент должен сообщить другому об изменении своего состояния, он отправляет сообщение вида:

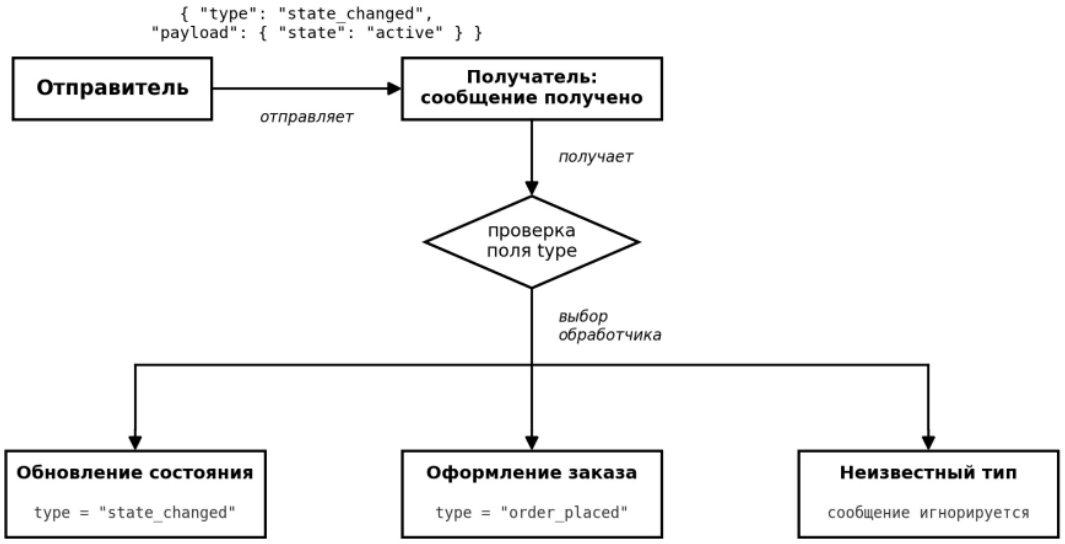


Рис. Обмен типизированным сообщением между отправителем и получателем

Такой подход близок к принципам событийно-ориентированной архитектуры и шаблону Publish/Subscribe, которые давно применяются при

интеграции разнородных программных компонентов. Компоненты системы не хранят прямых ссылок друг на друга и не вызывают методы друг друга напрямую, а обмениваются структурированными событиями через промежуточный слой – им может быть очередь сообщений, шина событий или простое сетевое соединение между двумя процессами [2].

Приведённое выше сообщение – это просто структура данных, которую можно закодировать на любом языке программирования. На Python, например, тип события удобно задать перечислением, а обработку – сопоставлением этого типа с функцией, которая его обрабатывает:

```
class EventKind(str, Enum):
    STATE_CHANGED = "state_changed"

def build_message(state: str) -> dict:
    return {"type": EventKind.STATE_CHANGED,
            "payload": {"state": state}}

handlers = {EventKind.STATE_CHANGED: apply_state}

def dispatch(message: dict) -> None:
    handler = handlers.get(message["type"])
    if handler:
        handler(message["payload"])
```

Принимающей стороне не нужна цепочка условий вида «если тип такой – сделать одно, если другой – сделать другое»: она просто ищет обработчик по полю type в заранее заполненном словаре handlers и передаёт ему данные. Новый тип сообщения добавляется одной строкой в этот словарь – без изменения кода, который обрабатывает уже существующие типы.

Одна и та же схема сообщений подходит не только для разового оповещения о событии – она может служить общим инструментом согласования, срабатывающим по разным основаниям:

• по времени – одно сообщение включает нужное состояние перед началом связанного с ним процесса, второе того же типа возвращает состояние по умолчанию после его завершения, так что видимая длительность состояния совпадает с длительностью процесса;

• по условию – сообщение того же вида отправляется не по расписанию, а при достижении определённого условия, например когда счётчик однотипных событий превышает заданный порог, а обратное сообщение возвращает систему в обычный режим, когда условие перестаёт выполняться.

В обоих случаях формат сообщений остаётся одним и тем же – меняется только то, что запускает его отправку.

Если бы компоненты системы вызывали методы друг друга напрямую, это сделало бы их зависимыми от конкретной реализации:

замена одного компонента потребовала бы синхронного изменения другого. Если бы вместо этого сообщения передавались вовсе без структуры, разбор формата пришлось бы дублировать в каждом месте, где сообщение обрабатывается, и любое изменение формата рисковало бы рассогласовать отправителя и получателя. Общий типизированный протокол занимает промежуточное положение между этими крайностями: он требует немного больше усилий на старте, поскольку набор типов сообщений и структуру данных нужно согласовать заранее, но избавляет от необходимости синхронно менять компоненты при каждой доработке. При большом числе типов сообщений и участников разработки желательно формально описывать структуру каждого типа, например средствами схемы данных, и автоматически проверять сообщения на соответствие ей [4].

Заключение. Использование единого типизированного протокола обмена сообщениями между отдельными компонентами интерактивной системы позволяет разрабатывать каждый компонент, а затем продолжать его разработку вместе с новыми типами взаимодействия, не беспокоясь о том, что изменение одного компонента незаметно нарушит работу другого. Данный подход не зависит от конкретного языка программирования или способа передачи данных и может применяться к разным систем, в которых отдельные части работают независимо и должны обмениваться событиями в реальном времени. Показанный пример на Python – один из вариантов применения. Идея одинаково хорошо работает на любом другом языке, поддерживающий словари (или их аналоги) и сопоставление значений с функциями.

Список литературы

1. Клеппман М. Высоконагруженные приложения. Программирование, масштабирование, поддержка / М. Клеппман. – Санкт-Петербург: Питер, 2019. – 640 с. – ISBN 978-5-4461-0724-6.
2. Летов Н. К. Применение технологии Server Side Events в событийно-ориентированных архитектурах высоконагруженных клиентских приложений / Н. К. Летов // Вестник науки. – 2025. – Т. 3, № 10 (91). – С. 622–631
3. Карпович М. Н. Особенности проектирования микросервисно-событийных архитектур для высоконагруженных распределенных систем обработки информаций / М. Н. Карпович // Труды БГТУ. Сер. 3, Физико-математические науки и информатика. – 2023. – № 1 (266). – С. 89–95. – DOI: 10.52065/2520-6141-2023-266-1-15.
4. JSON Schema Specification. – [Электронный ресурс] // JSON Schema: официальный сайт. – URL: https://json-schema.org (дата обращения 14.09.2026).

УДК 004.8

АНАЛИЗ ИСПОЛЬЗОВАНИЯ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБНАРУЖЕНИЯ СЕТЕВЫХ ВТОРЖЕНИЙ

Мартыненко А-А.М., ORCID 0009-0006-5009-8773, ***Умецкая Е.А.***
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
a.martinenko@donnu.ru, umetskaya_ekaterina@mail.ru

Введение. Число подключённых к сети устройств растёт быстрее, чем успевают адаптироваться классические средства защиты периметра, а вместе с этим усложняется и сам характер вредоносной активности. Сигнатурные системы обнаружения вторжений (IDS/IPS), рассчитанные на сравнение трафика с базой заранее известных шаблонов атак, хорошо справляются с уже описанными угрозами, но оказываются практически бесполезны против атак нулевого дня и слегка модифицированных версий известного вредоносного кода – злоумышленнику достаточно немного изменить паттерн, чтобы обойти фильтр. Отсюда возникает запрос на системы, которые ориентируются не на конкретную сигнатуру, а на поведение сети в целом, выявляя отклонения от привычной нормы.

Актуальность темы связана с тем, что вручную анализировать петабайты сетевого трафика в реальном времени уже невозможно, а ландшафт атак меняется быстрее, чем обновляются базы сигнатур. Машинное обучение в этой ситуации выступает инструментом, способным строить модель нормального поведения сети и автоматически сигнализировать об отклонениях, не дожидаясь, пока конкретную атаку опишут вручную.

Цель работы – рассмотреть, какие методы машинного обучения применяются сегодня для обнаружения сетевых вторжений, сопоставить их сильные и слабые стороны и обозначить проблемы, которые пока не решены до конца.

Основная часть. По способу выявления атак IDS условно делят на два лагеря: сигнатурные и поведенческие. Первые быстрые и не требуют больших вычислительных затрат, но бессильны перед тем, чего ещё нет в их базе. Вторые строят «портрет» нормального трафика и реагируют на любое существенное отклонение от него – ценой такого подхода становится более высокая доля ложных тревог, зато появляется шанс поймать то, что раньше никто не видел [1].

Из классических алгоритмов чаще всего в задачах такого рода используют деревья решений, случайный лес, метод опорных векторов и метод k-ближайших соседей – они хорошо работают, когда трафик уже описан набором числовых признаков (длительность сессии, объём данных, протокол и т.п.). Показательный пример – эксперимент на данных CICIDS2017, где дерево решений и случайный лес обучались отличать

нормальные соединения от веб-атак (brute force, XSS, SQL-инъекции); при этом авторы прямо отмечают, что итоговое качество модели сильно зависит не столько от самого алгоритма, сколько от того, насколько аккуратно подготовлены данные и подобраны признаки, а также от особенностей конкретной сети, на которой собирался трафик [2].

У глубокого обучения задача решается иначе: вместо ручного конструирования признаков сеть учится извлекать их сама, напрямую из необработанных данных. Свёрточные архитектуры удобны, когда трафик можно представить в виде матрицы значений – тогда становится видна пространственная структура пакета. Рекуррентные сети и LSTM, наоборот, лучше подходят там, где важна последовательность событий во времени. Обратная сторона этой гибкости – заметно более высокие требования к вычислительным ресурсам по сравнению с классическими моделями, поэтому выбор архитектуры на практике диктуется не модой, а конкретной задачей и доступными мощностями [3].

Отдельная сложность – где взять данные для обучения и как их оценивать. Один из показательных случаев касается набора NSL-KDD: он сильно разбалансирован по классам (атак в нём значительно меньше, чем «нормальных» примеров), и обучение нейросети напрямую на таких данных приводит к смещённой модели. Решение – модифицировать саму функцию потерь, чтобы редкие классы не «терялись» на фоне частых при обратном распространении ошибки [4]. Именно такие датасеты и позволяют потом сравнивать разные алгоритмы по единым метрикам – точности, полноте, доле ложных срабатываний, а не просто на словах.

Если сопоставить оба подхода напрямую, получается компромисс, а не однозначный победитель. Глубокие модели обычно точнее находят аномалии в большом и неоднородном по составу трафике, но платят за это временем на обучение и подбор гиперпараметров. Классические алгоритмы обучаются быстрее и остаются «прозрачными» – понятно, почему модель приняла то или иное решение, что критично именно в задачах безопасности, где аналитику нужно объяснить вердикт, а не просто получить цифру [5].

При этом ни один из подходов не решает несколько системных проблем. Во-первых, атаки в реальном трафике – это меньшинство, и модель, обученная на несбалансированных данных, рискует просто игнорировать редкий класс. Во-вторых, разметка качественного трафика – дорогое удовольствие, и хороших открытых датасетов немного. В-третьих – и это, пожалуй, самое неприятное – сами модели машинного обучения оказываются уязвимы для специально подобранных состязательных примеров: экспериментально показано, что нейросетевые детекторы вредоносного ПО можно обмануть, немного «пошевелив» входные данные так, чтобы классификатор ошибся, и одновременно предложены способы сделать такие модели устойчивее к подобным манипуляциям [6].

Насколько удачной получится модель, часто решает не алгоритм, а то, что ему подают на вход. Продолжительность соединения, объём переданных и принятых байт, число пакетов, протокол и порт, флаги TCP, статистика по трафику в скользящем окне – вот типичный набор признаков для сетевого потока. И, как показывает опыт с CICIDS2017, именно качество отбора и нормализации этих признаков в итоге определяет точность классификации сильнее, чем выбор между конкретными алгоритмами [2].

Заключение. Машинное обучение, особенно его «глубокая» ветвь, действительно даёт системам обнаружения вторжений то, чего не достаёт сигнатурному подходу – способность реагировать на атаки, которых раньше никто не видел. Однако, остаются нерешёнными вопросы интерпретируемости моделей, их устойчивости к состязательным атакам и адаптации к работе в реальном времени при ограниченных ресурсах сетевого оборудования – именно в этих направлениях.

Список литературы

1. Лукацкий, А. В. Обнаружение атак / А. В. Лукацкий. – 2-е изд., перераб. и доп. – Санкт-Петербург: БХВ-Петербург, 2003. – 596 с. – (Мастер систем). – ISBN 5-94157-246-8.
2. Горюнов, М. Н. Синтез модели машинного обучения для обнаружения компьютерных атак на основе набора данных CICIDS2017 / М. Н. Горюнов, А. Г. Мацкевич, Д. А. Рыболовлев // Труды ИСП РАН. – 2020. – Т. 32, № 5. – С. 81–93.
3. Гайфулина, Д. А. Применение методов глубокого обучения в задачах кибербезопасности. Часть 2 / Д. А. Гайфулина, И. В. Котенко // Вопросы кибербезопасности. – 2020. – № 4(38). – С. 11–21. – DOI 10.21681/2311-3456-2020-04-11-21.
4. Зуев, В. Н. Обнаружение аномалий сетевого трафика методом глубокого обучения / В. Н. Зуев // Программные продукты и системы. – 2021. – Т. 34, № 1. – С. 91–97. – DOI 10.15827/0236-235X.133.091-097.
5. Татарникова, Т. М. Выявление аномалий сетевого трафика методом глубокого обучения / Т. М. Татарникова, Ф. Бимбетов, П. Ю. Богданов // Известия СПбГЭТУ «ЛЭТИ». – 2021. – № 4. – С. 36–41.
6. Маршев, И. И. Защита от состязательных атак на средства обнаружения вредоносных программ с использованием алгоритмов машинного обучения / И. И. Маршев, Е. В. Жуковский, Е. Б. Александрова // Проблемы информационной безопасности. Компьютерные системы. – 2021. – № 1. – С. 50–54. – EDN XMPDGC.

УДК 004.942:669.187

ЦИФРОВОЙ ДВОЙНИК ДИАГНОСТИКИ ГАЗООТВОДЯЩЕГО ТРАКТА ДУГОВОЙ СТАЛЕПЛАВИЛЬНОЙ ПЕЧИ С СОВЕЩАТЕЛЬНЫМ КОНТУРОМ МАШИННОГО ОБУЧЕНИЯ

Мартыненко С.В., ORCID 0009-0004-9849-2919
ФГБОУ ВО «Вологодский государственный университет», г. Вологда, РФ
stepanmartynenko07@mail.ru

Введение. Системы поддержки принятия решений в металлургии строятся на основе цифровых двойников (ЦД) и машинного обучения. ЦД по ГОСТ Р 57700.372021– система, состоящая из цифровой модели изделия и двусторонних информационных связей с изделием (при наличии изделия) и (или) его составными частями [1]. Одной из задач таких систем является восстановление ненаблюдаемых переменных по косвенным измерениям. В работе представлены основные элементы разработанного цифрового двойника диагностики газоотводящего тракта дуговой сталеплавильной печи (ДСП). В цифровом двойнике по косвенному признаку потоку водорода в отходящих газах математически и алгоритмически разделяются два скрытых фактора, влажность металлической шихты и износ газоотводящего тракта. Математическая модель ЦД построена на фильтре Калмана с рекуррентной идентификацией параметров [2]. Верхний уровень поддержки решений реализован на нейросетевых моделях [3].

Цель работы – повышение эффективности мониторинга ДСП с помощью разработки цифрового двойника системы диагностики газоотводящего тракта ДСП, обеспечивающего совместную оценку влажности шихты и индекса износа по измеренному потоку водорода, прогноз остаточного ресурса и выдачу рекомендаций с совещательной поддержкой машинного обучения.

Основная часть. Объектом диагностики выступает ДСП с газоотводящим трактом, в тестовом режиме предусмотрен программный эмулятор плавки. В составе цифрового двойника выделены блоки: робастная предобработка измерений, комплексная математическая модель, реализующая совместное оценивание влажности шихты (w) и индекса износа (I), адаптация коэффициентов модели, прогноз остаточного ресурса (T_{res}), показатель вмешательства r(k), модуль машинного обучения (ML), параметры цифрового двойника и их временные ряды. Результаты выводятся на автоматизированное рабочее место (АРМ) оператора. Структурная схема программного комплекса приведена на рисунке.

Наблюдатель восстанавливает вектор состояния (1) по измерениям y(k).

$$x=[w, I]^T. \quad (1)$$

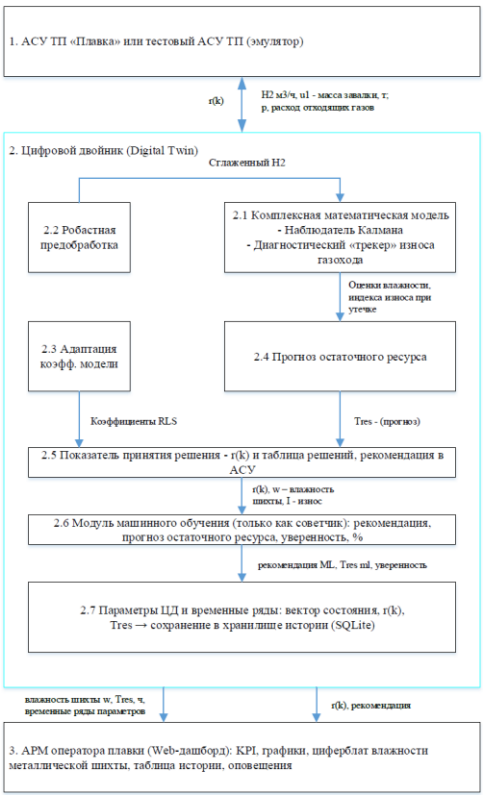


Рис. Структурная схема подсистемы диагностики на основе цифрового двойника

Для линейной модели наблюдения (2) усиление фильтра вычисляется по ковариациям ошибки оценивания и шума измерений. Апостериорная оценка состояния корректируется по выражению (3)

$$y(k)=C(k)\cdot x(k)+d, \quad (2)$$

где y(k) – измеренный поток водорода, C(k) – строка наблюдения, связывающая состояние с измерением, x(k) – вектор состояния (влажность шихты и индекс износа), d – постоянное смещение, учитывающее иные источники водорода.

$$\hat{x}(k|k)=\hat{x}(k|k-1)+K(k)\cdot[y(k)-C(k)\cdot\hat{x}(k|k-1)], \quad (3)$$

где $\hat{x}(k|k)$ – апостериорная оценка после коррекции, $\hat{x}(k|k-1)$ – априорная оценка вектора состояния до поступления измерения, K(k) – коэффициент усиления фильтра, y(k) – измеренный поток водорода, C(k) – строка наблюдения.

Разделение вкладов влажности и износа возможно только при изменении массы завалки шихты. Коэффициенты модели уточняются рекуррентным методом наименьших квадратов с фактором забывания. Показатель вмешательства автоматики r(k) формируется из оценок наблюдателя и характеризует степень необходимого вмешательства автоматики. Для каждого значения r(k) предусмотрено пороговое правило, преобразующее его в рекомендацию «Нормальный режим работы», «Требуется вмешательство» или «Аварийная остановка».» При сильном выбросе водорода авария фиксируется немедленно. Остаточный ресурс определяется линейной экстраполяцией текущей скорости роста индекса

износа до критического порога. Порог задается на предприятии в зависимости условий, возможности, опыта эксплуатации.

Совещательный контур машинного обучения построен на моделях MLPClassifier и MLPRegressor. Классификатор определяет класс состояния по максимуму апостериорной вероятности (4).

$$c^*=\text{argmax } P(c|x),\ P_{увер}=\max P(c|x), \quad (4)$$

где c – класс состояния («Нормальный режим работы», «Требуется вмешательство», «Аварийная остановка»), c* – класс, выбранный классификатором, P(c|x) – апостериорная вероятность класса c при векторе признаков x, $P_{увер}$ – уверенность классификатора, сравниваемая с порогом, * – математическое обозначение оптимального найденного значения. Рекомендация выводится оператору только при $P_{увер}\geq 0{,}7$, прогноз остаточного ресурса принимается при расхождении с физической моделью не более 30 %. Решающие действия остаются за детерминированным контуром, что соответствует требованиям промышленной безопасности.

Разработанный комплекс реализован на языке Python (FastAPI) с веб-дашбордом и хранением истории измерений (SQLite). В тестовом режиме предусмотрены три сценария эмулятора – нормальная плавка, влажная шихта, прорыв газохода. В заводских условиях данные принимаются по протоколам Modbus TCP и OPC-UA.

Заключение. Цифровой двойник позволяет выполнить раздельную оценку влажности шихты и индекса износа газоотводящего тракта по косвенному каналу водорода, прогноз остаточного ресурса и рекомендации оператору с совещательной поддержкой машинного обучения.

Список литературы

1. ГОСТ Р 57700.37-2021 Компьютерные модели и моделирование. Цифровые двойники изделий. Общие положения. – Введ. 2022-01-01. – М.: Российский институт стандартизации, 2021. – IV. – 15 с.
2. Осипова Н. В. Использование фильтра Калмана при автоматическом контроле показателей магнитного обогащения железных руд / Н. В. Осипова // Автоматизация в промышленности. – 2018. – Т. 61, № 5. – С. 372–377.
3. Нужин Д. В. Энергосберегающая система управления нагревом заготовок в проходных печах с использованием технологии цифрового двойника: дис. ... канд. техн. наук: 2.3.3 / Нужин Дмитрий Викторович. – Череповец, 2025. – 143 с.

УДК 004.8:336.76

ВЫЯВЛЕНИЕ АНОМАЛЬНЫХ КОЛЕБАНИЙ ФОНДОВОГО ИНДЕКСА МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

***Мельникова А.А.*[1],** ORCID 0009-0007-4273-1564,
***Бородин Г.А.*[2],** ORCID 0009-0007-0307-3044
[1]ФГОБУ ВО «Финансовый университет при Правительстве РФ», г. Москва, РФ
[2]ФГАОУ ВО «Российский государственный университет нефти и газа (НИУ) имени И.М. Губкина», г. Москва, РФ
melnikovaa731@gmail.com, bga9104@gmail.com

Автоматическое обнаружение редких событий важно для информационно-аналитических систем. На финансовом рынке такие события проявляются резкими колебаниями котировок. Выбор методов анализа цифровых данных значим для поддержки управленческих решений [1]. Цель исследования – сопоставить алгоритмы обнаружения экстремальных месячных доходностей NASDAQ на основе синхронных изменений котировок отдельных компаний.

Вопросы применения открытых и коммерческих инструментов Data Mining к экономическим данным рассмотрены в [2, 3]. Отраслевая специфика аналитических систем финансовой безопасности показана в [4]. Сравнение способов выявления деструктивных событий в информационных системах [5] иллюстрирует необходимость проверять разные алгоритмы на общей методике. В настоящей работе рассматриваются редкие изменения биржевых рядов.

Использован общедоступный набор Stocks.csv библиотеки Matplotlib, в исходном файле поставщиком котировок указан Yahoo Finance [7]. Выбраны месячные цены индекса NASDAQ Composite (^IXIC) и акций IBM, Apple, Microsoft, Adobe. После удаления служебных строк и пропусков вычислено 389 наблюдений за февраль 1990 – июнь 2022 г. Месячная логарифмическая доходность определялась как $r_t = 100\, ln(\frac{P_t}{P_{t-1}})$, где P_t – цена в месяце t. Восемь признаков составили доходности четырёх акций и их модули. Значения NASDAQ служили только для разметки целевой переменной и не входили в признаки.

Первые 203 наблюдения (февраль 1990 – декабрь 2006 г.) образовали обучающую выборку, следующие 186 (январь 2007 – июнь 2022 г.) – тестовую. Экстремальным считался месяц с модулем доходности NASDAQ не ниже 85-го процентиля модуля на обучении (10,0875 %). Получено 31 событие на обучении и 12 – на тесте. Хронологическое разделение и вычисление порогов и параметров масштабирования только на обучающих данных предотвращают утечку тестовой информации.

Исследованы логистическая регрессия с масштабированием и балансировкой классов, случайный лес из 300 деревьев (максимальная глубина 5, балансировка классов) и Isolation Forest [6] из 300 деревьев (contamination = 0,10). Для классификаторов с учителем порог вероятности принят равным 0,5. Базовый метод фиксировал событие при превышении максимумом модулей доходности четырёх акций порога 27,3404 %, рассчитанного по 85-му процентилю на обучении.

На тесте оценивались Precision (доля верных сигналов), Recall (доля обнаруженных событий), F1-мера, ROC-AUC, число найденных событий (TP) и ложных тревог (FP). Общая доля верных классификаций Accuracy при редком положительном классе недостаточно информативна. Полученные запуском программы значения приведены в таблице.

Таблица

Результаты обнаружения экстремальных месяцев на тестовых данных

Метод	**TP/FP**	**Precision**	**Recall**	**F1**	**ROC-AUC**
Логист. регрессия	6/6	0,500	0,500	0,500	0,919
Случайный лес	4/1	0,800	0,333	0,471	0,861
Isolation Forest	2/1	0,667	0,167	0,267	0,807
Пороговый метод	3/0	1,000	0,250	0,400	0,906

В тестовый период экстремальные месяцы наблюдались, например, осенью 2008 г. и весной 2020 г. Выбор модели зависит от относительной стоимости пропуска события и ложной тревоги: логистическая регрессия обеспечивает более высокую полноту, случайный лес – меньше ошибочных сигналов. Однако 12 положительных наблюдений не позволяют утверждать устойчивое превосходство одной модели. Доля событий снизилась с 15,3 % в обучающей части до 6,5 % в тестовой, что подчёркивает изменчивость рынка. ROC-AUC характеризует ранжирование при всех порогах, а не полноту при фиксированном пороге 0,5.

Поскольку используемые признаки и целевое событие относятся к одному месяцу, полученные результаты характеризуют способность моделей обнаруживать уже произошедшие экстремальные колебания, но не прогнозировать их. При этом возможности обобщения результатов ограничены использованием котировок лишь четырёх компаний и временным охватом данных, завершающимся июнем 2022 года. Кроме того, выбранный порог экстремальности зависит от рассматриваемого исторического периода. Для повышения практической применимости предложенного подхода необходимо расширить перечень финансовых инструментов, провести скользящую временную валидацию и определить оптимальный порог обнаружения на отдельной валидационной выборке.

Создан проект по обнаружению экстремальных месячных изменений NASDAQ на реальных открытых данных. Лучшее в данном тесте значение F1 = 0,500 обеспечила логистическая регрессия, случайный лес сократил

ложные срабатывания до одного. Результат демонстрирует применение машинного обучения без прямой утечки целевого признака и существенный компромисс между полнотой обнаружения и точностью сигналов.

Список литературы

1. Мельников, В. А. Анализ современных методик оценки экономической эффективности цифровой трансформации / В. А. Мельников, А. А. Мельникова // Цифровое общество: образование, экономика, технологии: Сборник трудов IV Международной научно-практической конференции, Новокузнецк, 18–19 марта 2026 года. – Москва: ООО «Актуальность.РФ», 2026. – С. 188-194. – EDN NGHSYH.
2. Мельников, В. А. Анализ применимости открытых инструментов работы с алгоритмами Data Mining для решения задач анализа экономических данных / В. А. Мельников, А. А. Першина, Н. А. Савченко // Актуальные проблемы нефти и газа: Сборник трудов VII Всероссийской молодежной научной конференции, Москва, 16–18 октября 2024 года. – Москва: Институт проблем нефти и газа РАН, 2024. – С. 360-361. – EDN UIKEBJ.
3. Мельников, В. А. Оценка коммерческих инструментов работы с алгоритмами Data Mining / В. А. Мельников, А. А. Першина, Н. А. Савченко // Губкинский университет в решении вопросов нефтегазовой отрасли России: Тезисы докладов VIII Региональной научно-технической конференции, посвященной 100-летию профессора Ю.П. Желтова, Москва, 07–11 октября 2024 года. – Москва: Российский государственный университет нефти и газа (национальный исследовательский университет) им. И.М. Губкина, 2024. – С. 434-435. – EDN SJRFEZ.
4. Мельников, В. А. Классификация информационно-аналитических систем безопасности в финансовых и экономических структурах по назначению / В. А. Мельников, А. А. Першина // Новые технологии в газовой промышленности (газ, нефть, энергетика): Тезисы докладов, Москва, 23–27 октября 2023 года. – Москва: Российский государственный университет нефти и газа (национальный исследовательский университет) им. И.М. Губкина, 2023. – С. 315-316. – EDN VHYHKN.
5. Мельников В. А. Подходы к выявлению деструктивных действий и событий в информационных системах / В. А. Мельников, П. Ю. Пушкин, А. А. Мельникова и др. // Системы высокой доступности. – 2026. – Т. 22. – № 3. – С. 112−125. DOI: https://doi.org/10.18127/j20729472-202603-10.
6. Liu F. T. Isolation Forest / F. T. Liu, K. M. Ting, Z.-H. Zhou // Proceedings of the 8th IEEE International Conference on Data Mining (ICDM 2008). – Pisa, 2008. – P. 413–422. DOI: 10.1109/ICDM.2008.17.
7. Matplotlib. Stocks.csv: исторические котировки акций и индексов (источник данных: Yahoo Finance) [Электронный ресурс]. URL: https://raw.githubusercontent.com/matplotlib/matplotlib/main/lib/matplotlib/mpl-data/sample_data/Stocks.csv (дата обращения: 08.10.2026).

УДК 004.056.5

ВЫЯВЛЕНИЕ ФИШИНГОВЫХ ВЕБ-САЙТОВ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ НА ОСНОВЕ ПОВЕДЕНЧЕСКИХ ПРИЗНАКОВ

***Мельникова А.А.*[1],** ORCID 0009-0007-4273-1564,
***Бородин Г.А.*[2],** ORCID 0009-0007-0307-3044
[1]ФГОБУ ВО «Финансовый университет при Правительстве РФ», г. Москва, РФ
[2]ФГАОУ ВО «Российский государственный университет нефти и газа (НИУ) имени И.М. Губкина», г. Москва, РФ
melnikovaa731@gmail.com, bga9104@gmail.com

Фишинг остается одним из распространенных способов реализации атак, в которых технические и социальные приемы используются совместно. Поэтому задача защиты не ограничивается блокированием отдельных адресов: требуется автоматизированное выявление совокупности признаков, отличающих потенциально опасный ресурс от легитимного. В работе [1] рассматриваются подходы к выявлению деструктивных действий и событий в информационных системах, а в [2] представлена классификация технологий применения фишинга как метода социальной инженерии. Цель настоящего исследования – разработка и экспериментальная оценка компактного классификатора, который по формализованным характеристикам веб-сайта определяет принадлежность объекта к фишинговому классу.

Возможности открытых инструментов Data Mining рассматривались, в частности, в [3]. В контексте информационной безопасности такой классификатор может выступать аналитическим компонентом системы мониторинга [4], дополняющим технологии защищенной передачи информации [5] и инструментальный аудит программной среды [6].

Эксперимент проведен на открытом наборе Website Phishing из UCI Machine Learning Repository [7]. Набор включает 1353 веб-сайта и девять целочисленных признаков. Целевой признак Result принимает три значения: 1 для легитимного сайта, 0 для подозрительного и -1 для фишингового. Согласно описанию UCI, в наборе 548 легитимных, 103 подозрительных и 702 фишинговых объекта, пропущенные значения отсутствуют [7]. Для получения однозначной бинарной постановки 103 объекта класса suspicious исключены. Итоговая выборка включает 1250 наблюдений: 702 фишинговых и 548 легитимных.

Данные разделены на обучающую и контрольную части в соотношении 75:25 со стратификацией, контрольная выборка составила 313 объектов. На обучающей части дополнительно выполнена пятикратная стратифицированная кросс-валидация. Сравнивались три алгоритма: логистическая регрессия, дерево решений и случайный лес. Для

логистической регрессии признаки стандартизировались. Для дерева ограничивались максимальная глубина и минимальное число объектов в листе, а случайный лес сформирован из 500 деревьев с балансировкой весов классов.

Качество оценивалось по accuracy, precision, recall, F1, balanced accuracy, ROC-AUC, доле ложноположительных срабатываний (FPR) и коэффициенту корреляции Мэтьюса (MCC). Одной accuracy недостаточно, поскольку пропуск фишингового ресурса и ложная блокировка легитимного сайта имеют различный практический смысл. Поэтому основными показателями использованы F1 и balanced accuracy, ROC-AUC характеризует разделимость классов, а FPR – число ложных тревог. Полученные результаты приведены в таблице.

Таблица

Результаты классификации на контрольной выборке

Модель	**F1**	**Balanced acc.**	**ROC-AUC**	**FPR**
Logistic Regression	0,917	0,906	0,961	0,102
Decision Tree	0,913	0,905	0,960	0,088
Random Forest	0,926	0,916	0,980	0,095

Наименьшая доля ложноположительных срабатываний получена для дерева решений (FPR=0,088), тогда как для Random Forest она составила 0,095, а для Logistic Regression – 0,102.

Наибольшее значение F1 получено для Random Forest (0,926, balanced accuracy 0,916, ROC-AUC 0,980). Наиболее информативными признаками этой модели оказались SFH, SSLfinal_State и popUpWindow. Их вклад показывает, что решение учитывает особенности обработки форм, состояние SSL-соединения и использование всплывающих окон. Модель не заменяет экспертную проверку, но может использоваться как первичный фильтр, ранжирующий веб-ресурсы по вероятности фишингового характера и передающий наиболее подозрительные объекты на последующий анализ.

Ограничением эксперимента является то, что набор содержит заранее вычисленные признаки, а не исходное содержимое веб-страниц, кроме того, данные были собраны ранее и не отражают все современные приемы маскировки фишинговых ресурсов. Дальнейшее развитие проекта связано с проверкой модели на более новых наборах URL, добавлением лексических признаков адреса и оценкой устойчивости классификатора к изменению распределения данных.

Таким образом, предложен конвейер бинарной классификации фишинговых веб-сайтов, включающий подготовку открытых данных, сопоставление трех алгоритмов, оценку по взаимодополняющим метрикам и интерпретацию признаков. В проведенном эксперименте Random Forest показал наибольшие F1 и ROC-AUC. Практическая ценность решения

состоит в возможности использовать его как компактный аналитический модуль предварительного выявления потенциально деструктивных веб-ресурсов в составе средств мониторинга информационной безопасности.

Список литературы

1. Мельников В. А. Подходы к выявлению деструктивных действий и событий в информационных системах / В. А. Мельников, П. Ю. Пушкин, А. А. Мельникова и др. // Системы высокой доступности. – 2026. – Т. 22. – № 3. – С. 112−125. DOI: https://doi.org/10.18127/j20729472-202603-10
2. Мельников, В. А. Классификация технологий применения фишинга в качестве метода социальной инженерии / В. А. Мельников, А. А. Першина // Новые технологии в газовой промышленности (газ, нефть, энергетика): Тезисы докладов, Москва, 23–27 октября 2023 года. – Москва: Российский государственный университет нефти и газа (национальный исследовательский университет) им. И.М. Губкина, 2023. – С. 307-308. – EDN VVHDRR.
3. Мельников, В. А. Анализ применимости открытых инструментов работы с алгоритмами Data Mining для решения задач анализа экономических данных / В. А. Мельников, А. А. Першина, Н. А. Савченко // Актуальные проблемы нефти и газа: Сборник трудов VII Всероссийской молодежной научной конференции, Москва, 16–18 октября 2024 года. – Москва: Институт проблем нефти и газа РАН, 2024. – С. 360-361. – EDN UIKEBJ.
4. Мельников, В. А. Классификация информационно-аналитических систем безопасности в финансовых и экономических структурах по назначению / В. А. Мельников, А. А. Першина // Новые технологии в газовой промышленности (газ, нефть, энергетика): Тезисы докладов, Москва, 23–27 октября 2023 года. – Москва: Российский государственный университет нефти и газа (национальный исследовательский университет) им. И.М. Губкина, 2023. – С. 315-316. – EDN VHYHKN.
5. Мельников, В. А. Исследование существующих методов и технологий обеспечения защищенной передачи информации / В. А. Мельников // Цифровое общество: образование, экономика, технологии: Материалы III Международной научно-практической конференции, Новокузнецк, 18–19 марта 2025 года. – Москва: ООО «Актуальность.РФ», 2025. – С. 299-304. – EDN OYPKNT.
6. Мельников, В. А. Инструменты для аудита безопасности на ALT Linux на примере Lynis / В. А. Мельников, А. А. Першина // Глобальные научные тренды: междисциплинарные исследования: Сборник статей II Международной научно-практической конференции, Саратов, 25 марта 2025 года. Часть 1. – Саратов: ООО Издательство «Кубик», 2025. – С. 90-102. – EDN DBAKYT.
7. Abdelhamid N. Website Phishing [Dataset] // UCI Machine Learning Repository. 2014. DOI: 10.24432/C5B301. URL: https://archive.ics.uci.edu/dataset/379/website%2Bphishing.

УДК 004.932:616.314-073.75

УСКОРЕНИЕ РАЗМЕТКИ ПАНОРАМНЫХ РЕНТГЕНОГРАММ ЗУБОВ С ПРИМЕНЕНИЕМ МУЛЬТИМОДАЛЬНЫХ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ

Михайлович Е.В., канд. техн. наук, ORCID 0009-0003-7818-8314,
Белоусова В.С., ORCID 0000-0003-1362-6283
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
viktoria.belousova.work@yandex.ru, dist.obbuch@gmail.com

Введение. В настоящее время разметка остаётся одним из наиболее ресурсоёмких этапов. Традиционные подходы, основанные на ручной разметке, характеризуются высокой стоимостью, длительными сроками выполнения и ограниченной масштабируемостью при работе с большими объёмами информации. Появление больших языковых моделей (LLM) открывает новые возможности для автоматизации и ускорения процессов аннотации.

Цель работы – оценить, насколько гибридный подход ускоряет разметку панорамных рентгенограмм зубов. В этом подходе мультимодальная LLM выполняет предварительную детекцию зубов, а человек проверяет результат, исправляет рамки и присваивает диагностические классы.

Основная часть. Существующие способы применения LLM для разметки данных можно свести к нескольким схемам.

Первая схема – автономная разметка, когда модель получает данные и инструкцию и сама формирует метки. На типовых данных результаты приемлемы, а на узкоспециализированных, в том числе медицинских, доля ошибок заметно растёт. Вторая схема – совместная работа человека и модели (human-in-the-loop). Модель размечает весь массив, а человеку на проверку выборочно передаются наиболее неоднозначные примеры. Третья схема – согласование результатов нескольких моделей. Метки, на которых модели расходятся, направляются на проверку, а совпадающие принимаются. Это снижает влияние систематических ошибок отдельной модели.

Качество разметки на всех трёх схемах повышают методы составления запросов. Few-shot prompting предполагает, что в запрос включаются несколько эталонных пар «вход – выход», и модель перенимает формат и логику разметки без дообучения. Метод цепочки рассуждений (Chain-of-Thought) побуждает модель решать задачу пошагово, что полезно при разметке сложных объектов. Для детекции на изображениях есть и альтернатива MLLM: специализированные модели с открытым словарём классов, такие как Grounding DINO и Segment Anything [1-2].

Для демонстрации рассмотрим задачу детекции зубов на ортопантомограммах. Это задача, требующая высокой точности локализации

анатомических структур. Разметка выполняется в два этапа. На первом этапе мультимодальная LLM, (например Claude Opus 5.5, Claude Sonnet 5.5, Kimi K3; дата проведения экспериментов – 03.10.2026 г.) получает снимок и инструкцию обвести каждый зуб рамкой. Разметка ведётся по одному классу tooth. Модель возвращает координаты рамок в формате JSON, они преобразуются в формат YOLO и импортируются в Roboflow. На втором этапе аннотатор в Roboflow работает с уже предразмеченным снимком: удаляет ложные и дублирующиеся рамки, добавляет пропущенные зубы, уточняет границы и назначает каждому зубу диагностический класс [3].

Перед ручной проверкой рамки предлагается отфильтровать по простым правилам. Две рамки с пересечением (IoU) выше 0,5 считаются дублем. Рамки, касающиеся края изображения или выходящие за область зубных дуг, отмечаются как вероятное ложное срабатывание. Подозрительными считаются также рамки с нетипичным размером или соотношением сторон и снимки, где число найденных зубов резко отличается от ожидаемого для данного типа прикуса. Снимки, на которых сработало хотя бы одно правило, проверяются в первую очередь.

Размеченный набор из 300–500 снимков планируется использовать для обучения детекторов YOLOv8n и YOLOv8s в Google Colab. На рисунке приведены примеры предварительной разметки. LLM находит большинство зубов на снимках как с постоянным, так и со сменным прикусом. Типичные ошибки: дублирующиеся рамки на одном зубе (снимок а), ложные срабатывания на структурах у края снимка (снимок а), неточные границы у зубов с наложением изображений и у непрорезавшихся зубов, а также ошибки на снимках с имплантатами и ортопедическими конструкциями (снимок д)[4].

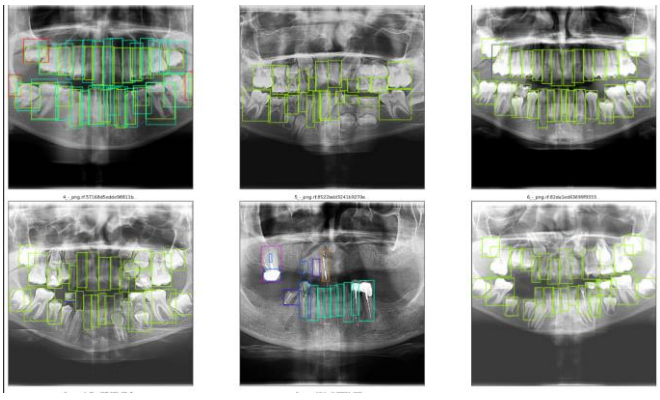


Рис. Примеры предварительной разметки панорамных рентгенограмм мультимодальной LLM: а–е – снимки из набора данных; цвет рамки соответствует: классу разметки

Оценка эффективности. Качество предварительной разметки оценивалось на 10 снимках. Эталоном служила ручная разметка, проверенная человеком. Рамка LLM считалась верной, если её пересечение

с эталонной рамкой составляло IoU ≥ 0,5 [20]. По этому критерию вычислялись точность (precision), полнота (recall) и F1-мера. Время работы аннотатора измерялось хронометражем отдельно для разметки с нуля и для проверки предразметки.

Таблица

Оценка эффективности

Показатель	Значение
Число эталонных зубов (среднее по 10 снимкам)	22
Precision / Recall / F1 при IoU ≥ 0,5	0,846 / 0,956 / 0,898
Средний IoU верных рамок	0,85
Время ручной разметки снимка, мин	20–30, N = 10
Время проверки предразметки, мин	5–7, N = 10

Результаты следует рассматривать как предварительные. Выборка мала, проверку выполнял один аннотатор, а метрики для разных LLM не сравнивались. Для более надёжных выводов нужна оценка на большем числе снимков и согласованность между несколькими экспертами.

Заключение. Мультимодальные LLM пригодны для предварительной детекции зубов на панорамных рентгенограммах. В проведённом эксперименте проверка предразметки заняла 5–7 минут на снимок против 20–30 минут при ручной разметке. LLM не заменяет аннотатора: её результаты содержат дубли, пропуски и ложные срабатывания, а диагностические классы и проверку назначает человек. Дальнейшая работа включает оценку на расширенной выборке, сравнение нескольких моделей по единым метрикам, обучение детектора YOLOv8 на полученном наборе и проверку эвристики нумерации по FDI. Перспективным направлением выглядят также специализированные стоматологические MLLM.

Список литературы

1. Large Language Models for Data Annotation and Synthesis: A Survey / Z. Tan, D. Li, S. Wang [et al.] // Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing. – 2024. – URL: https://arxiv.org/abs/2402.13446 (дата обращения: 04.10.2026).
2. The performance of large language models in dentomaxillofacial radiology: a systematic review / Z. Liu, A. Nalley, J. Hao [et al.] // Dentomaxillofacial Radiology. – 2025. – Vol. 54, № 8. – P. 613–631. – DOI 10.1093/dmfr/twaf060.
3. Tufts Dental Database: A Multimodal Panoramic X-Ray Dataset for Benchmarking Diagnostic Systems / K. Panetta [et al.] // IEEE Journal of Biomedical and Health Informatics. – 2022. – Vol. 26, № 4. – P. 1650–1659. – DOI 10.1109/JBHI.2021.3117575.
4. План мероприятий по повышению эффективности реализации датасета STS‑2D‑Tooth / MedOtter // Hugging Face: официальный сайт. – 2024. – Текст: электронный. – URL: https://huggingface.co/datasets/MedOtter/STS-2D-Tooth (дата обращения: 04.10.2026).

УДК 004.89:004.912

СИСТЕМА КЛАССИФИКАЦИИ РУССКОЯЗЫЧНЫХ ТЕКСТОВЫХ СООБЩЕНИЙ ИНТЕРНЕТ-МЕССЕНДЖЕРОВ ПО КАТЕГОРИЯМ РИСКА НА ОСНОВЕ ТРАНСФОРМЕРНЫХ МОДЕЛЕЙ

Мищук В.В., ORCID 0009-0004-1677-5000,
Бондаренко В.И., канд. техн. наук, доц., ORCID 0000-0002-5404-5787,
SPIN-код 5871-9382
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
win.04@mail.ru, bondarenko@donnu.ru

Введение. Интернет-мессенджеры стали одной из основных площадок обмена информацией и одновременно каналом распространения спама, мошенничества, агрессии и иного вредоносного контента. Ручная модерация и фильтры, по ключевым словам, не справляются с объёмом и скоростью обновления таких потоков. Существующие решения, как правило, закрыты либо обучены на данных другого типа – письмах и SMS [1], – и плохо учитывают специфику мессенджеров: короткие неформальные сообщения, сленг, эмодзи, транслит, опечатки и намеренную маскировку текста. Быстрая смена тактик спамеров приводит к дрейфу концепции – изменению свойств данных со временем [2], а для русскоязычного сегмента не хватает воспроизводимых конвейеров обработки данных.

Цель. Разработать и экспериментально оценить систему автоматической классификации сообщений мессенджеров по категориям риска (спам, мошенничество, агрессия, безопасный контент) с ориентацией на русскоязычный неформальный стиль. Качество оценивается не только точностью, но и балансом между скоростью обработки и долей ложных срабатываний, что принципиально для модерации.

Основная часть. Система рассчитана на сценарии с легальной обработкой контента: публичные каналы, корпоративные платформы, клиентские приложения с согласия пользователя (корпоративная безопасность, родительский контроль, модерация чатов). Приватные зашифрованные чаты, голос и видео не анализируются, а спорные случаи решает модератор.

Категории риска определяются по следующим признакам: к спаму относятся массовые рекламные и навязчивые рассылки; к мошенничеству – сообщения, направленные на получение денег, персональных данных или доступа к аккаунтам (фишинговые ссылки, ложные выигрыши, обращения от имени «службы безопасности»); к агрессии – оскорбления, угрозы и травля; остальные сообщения считаются безопасным контентом. Типы ошибок для модерации неравнозначны: пропуск угрозы снижает защищённость пользователей, а ложное срабатывание приводит к блокировке легитимных сообщений и лишней нагрузке на модератора, поэтому порог

принятия решения подбирается для каждой категории с учётом допустимой доли ложных срабатываний. Поскольку доля мошенничества и агрессии в потоке невелика, наряду с общей точностью используется макроусреднённая F1-мера, не позволяющая высоким качеством на массовом классе скрыть слабые результаты на редких категориях.

Подходы к классификации текста развивались от ключевых слов, наивного байесовского классификатора и метода опорных векторов к рекуррентным сетям с вниманием и трансформерам, таким как BERT и его варианты, включая RoBERTa. Механизм внимания учитывает контекстные зависимости между словами, что важно для выявления скрытых угроз; для русского языка доступна предобученная модель RuBERT [3]. Эффективность глубоких языковых моделей для русскоязычных текстов показана на задачах определения тональности [4] и классификации научных текстов [5].

Система включает сбор и разметку данных, предобработку, обучение и сравнение моделей, развёртывание. Данные берутся из открытых источников – академических наборов, подобных SMS Spam Collection [1], и публичных каналов; часть примеров размечается вручную, персональные данные удаляются. Формирование обучающих наборов из «сырых» текстов для дообучения языковых моделей рассматривалось в [6]. Предобработка включает приведение текста к единому виду, обработку эмодзи, транслита и опечаток, удаление невидимых символов и нормализацию сленга, что служит и первой мерой защиты от состязательной маскировки; примеры искажённых текстов добавляются в обучающие данные. Неравномерность классов компенсируется взвешенной функцией потерь. Тестовая выборка формируется из более поздних сообщений и источников, не использованных при обучении.

В качестве базовых моделей реализованы логистическая регрессия на признаках ключевых слов и LSTM с механизмом внимания. Основной упор сделан на дообучение русскоязычных RuBERT и RoBERTa методом низкоранговой адаптации LoRA [7], при котором обновляется лишь небольшая доля параметров, что снижает затраты памяти и времени. Реализация выполняется на PyTorch с библиотекой Transformers (HuggingFace), эксперименты фиксируются в Weights & Biases для воспроизводимости.

Качество оценивается по точности (precision), полноте (recall) и F1-мере по классам, доле ложных срабатываний (False Positive Rate) и времени обработки: после оптимизации в формате ONNX целевое значение – 50–100 мс на сообщение. Отдельно проверяются устойчивость к искажённым текстам и к дрейфу концепции на более поздних выборках. Для демонстрации разработан интерфейс на FastAPI; среда будет упакована в Docker-контейнер. Сообщения с низкой уверенностью модели передаются модератору, а его решения используются для дообучения.

Подтверждённые и исправленные модератором решения накапливаются в дополнительной размеченной выборке и позволяют периодически адаптировать модель к смене тактик спамеров и мошенников.

Заключение. Предложена система классификации русскоязычных сообщений мессенджеров по категориям риска, объединяющая подготовку и разметку данных, нормализацию неформального текста, дообучение трансформерных моделей методом LoRA и передачу сообщений с низкой уверенностью модератору. На текущем этапе выполнены обзор литературы, постановка задачи и определение границ применения, подготовлена среда экспериментов, реализованы базовые модели (логистическая регрессия, LSTM с вниманием) и проведены первые тесты. Следующие шаги – сравнение архитектур по precision, recall, F1-мере, доле ложных срабатываний и времени обработки, проверка устойчивости к искажённым текстам и дрейфу концепции, анализ ошибок и подготовка демонстрационного стенда. Система не заменяет модератора, а помогает отсеивать очевидные угрозы; перспективными направлениями являются анализ изображений и расширение набора категорий.

Список литературы

1. Almeida T. A. Contributions to the study of SMS spam filtering: new collection and results / T. A. Almeida, J. M. Gómez Hidalgo, A. Yamakami // Proceedings of the 11th ACM Symposium on Document Engineering (DocEng ’11). – New York: ACM, 2011. – P. 259–262. – DOI 10.1145/2034691.2034742.
2. Gama J. A survey on concept drift adaptation / J. Gama, I. Žliobaitė, A. Bifet et al. // ACM Computing Surveys. – 2014. – Vol. 46, № 4. – Article 44. – DOI 10.1145/2523813.
3. Kuratov Y. Adaptation of deep bidirectional multilingual transformers for Russian language / Y. Kuratov, M. Arkhipov // arXiv preprint arXiv:1905.07213. – 2019.
4. Бондаренко В. И. Анализ эффективности глубоких языковых моделей для задачи определения тональности русскоязычных текстов / В. И. Бондаренко, В. О. Елисеев, Т. В. Ермоленко // Проблемы искусственного интеллекта. – 2024. – № 1 (32). – С. 51–62. – EDN KJRRQW.
5. Бондаренко В. И. Классификация научных текстов с помощью методов глубокого машинного обучения / В. И. Бондаренко // Вестник Донецкого национального университета. Серия Г: Технические науки. – 2021. – № 3. – С. 69–77. – EDN FJPQFE.
6. Eliseev V. O. Transforming raw corporate texts into instruction dataset for fine-tuning generator within a RAG system / V. O. Eliseev, A. Yu. Maksimova, V. I. Bondarenko // System Informatics. – 2025. – № 27. – P. 77–92. – DOI 10.31144/si.2307-6410.2025.n27.p77-92. – EDN KISRSE.
7. Hu E. J. LoRA: low-rank adaptation of large language models / E. J. Hu, Y. Shen, P. Wallis et al. // arXiv preprint arXiv:2106.09685. – 2021.

УДК 004.032.26

ОТ СПАЙКОВЫХ НЕЙРОННЫХ СЕТЕЙ К КОННЕКТОМНЫМ МОДЕЛЯМ ЗРЕНИЯ В ЗАДАЧЕ СОПРОВОЖДЕНИЯ ОБЪЕКТОВ

***Мороз Е.С.*[1,2]**, ORCID 0009-0001-2472-9328,
***Герасимова В.С.*[2]**, ORCID 0009-0005-2257-4448
[1]ФГБНУ «Институт проблем искусственного интеллекта», г. Донецк, РФ
[2]ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
azidaan.moroz@yandex.com, vika_gera2097@mail.ru

Введение. Многообъектный трекинг ухудшается при слабом освещении и пересвете: детектор пропускает объекты, а оценка движения страдает от шума и низкого контраста. Детекторы строятся на свёрточных сетях, элементом которых служит формальный нейрон (упрощённая модель нервной клетки): он реагирует только на текущий сигнал и не помнит предыдущих. У биологического нейрона (нервной клетки) ответ зависит и от недавнего прошлого, а зрительная система животных (глаз и зрительные отделы мозга) экономно справляется с сумерками и бликами. Цель работы – рассмотреть принципы спайковых и коннектомных (повторяющих схему связей мозга) нейронных сетей и проверить пользу модели зрения дрозофилы при сопровождении объектов.

Основная часть. Нервная клетка накапливает возбуждение от входящих сигналов; когда оно превышает порог, она посылает короткий электрический импульс (спайк) всегда одинаковой силы. Информацию несут частота и моменты импульсов [1, 2]. Спайковые нейронные сети (СНС) – «третье поколение» нейросетевых моделей [3] – переносят этот принцип, работая лишь в моменты импульсов, они экономичны на нейроморфных процессорах (микросхемах по образцу нервной системы) [4], но обучать их сложнее.

Другой путь – взять готовую схему зрительной системы животного, например плодовой мушки (дрозофилы): её мозг недавно полностью оцифрован: составлена карта всех её примерно 140 тыс. нейронов и их связей – коннектом [5]. Свет улавливают фоторецепторы R1–R6 в каждом из примерно 750 глазков фасеточного глаза. Затем сигнал проходит три слоя зрительной доли: *ламину*, где он выравнивается по яркости и делится на каналы светлых и тёмных изменений, *медуллу*, где соседние точки изображения сравниваются во времени, и *лобулу*, где выделяются движение и форма объектов. Нейроны T4 и T5 различают направление движения светлых и тёмных краёв. Причём фоторецепторы [1] и большинство нейронов первых слоёв общаются не импульсами, а плавным изменением напряжения. По карте связей зрительной системы мухи построена компьютерная модель FlyVis [6]: 45 669 нейронов 64 типов и около 1,5 млн связей. Нейроны модели работают как настоящие: T4 и T5 сами начали различать направление движения.

FlyVis проверена в ряде экспериментов по сопровождению объектов на видео: на каждый объект наводился отдельный «глаз» модели, а отклики её нейронов служили оценкой движения объекта, признаком надёжности предсказания его положения и «отпечатком» объекта для повторного опознания после потери. На тёмных видео она работала хуже: она приучена к ярким изображениям. Перед ней добавлен блок «фоторецептор + ламина», повторяющий работу первых слоёв глаза: он подстраивает чувствительность к общей яркости сцены, как глаз привыкает к темноте (закон Вебера), и подчёркивает границы объектов, как это делают соседние клетки сетчатки, подавляя друг друга (латеральное торможение, антагонизм «центр – окружение»). С этим блоком «отпечаток» модели повышает точность различения «тот же объект или другой» с 0,438 до 0,582. Чтобы отличить пользу самой схемы мухи от пользы просто большого числа нейронов, связи модели случайно перемешали, сохранив их число и силу: нейронов и связей осталось столько же, но соединены они уже не так, как у мухи. Точность «отпечатка» при этом падает с 0,582 до 0,522, причём ухудшение видно в 29 из 35 тестовых видео. Значит, заметную часть сведений об объекте даёт именно то, как соединены нейроны мухи, – схема, сложившаяся за миллионы лет эволюции.

Заключение. Спайковые сети переносят из биологии способ передачи сигнала, а коннектомные – саму схему связей. Оцифровка мозга позволит брать у природы готовые решения и делать нейросетевые технологии лучше и экономнее, а опыты с моделью мухи показывают, что подход уже применим.

Список литературы

1. Труш, В. В. Физиология человека и животных: конспект лекций / В. В. Труш; Донецкий нац. ун-т. – Донецк, 2016. – 370 с.
2. Физиология человека: в 3 т. Т. 1 / под ред. Р. Шмидта, Г. Тевса; пер. с англ. – Москва: Мир, 1996. – 323 с. – ISBN 5-03-002544-8.
3. Maass, W. Networks of spiking neurons: the third generation of neural network models / W. Maass // Neural Networks. – 1997. – Vol. 10, № 9. – P. 1659–1671. – DOI 10.1016/S0893-6080(97)00011-7.
4. Roy, K. Towards spike-based machine intelligence with neuromorphic computing / K. Roy, A. Jaiswal, P. Panda // Nature. – 2019. – Vol. 575, № 7784. – P. 607–617. – DOI 10.1038/s41586-019-1677-2.
5. Neuronal wiring diagram of an adult brain / S. Dorkenwald, A. Matsliah, A. R. Sterling [et al.] // Nature. – 2024. – Vol. 634, № 8032. – P. 124–138. – DOI 10.1038/s41586-024-07558-y.
6. Connectome-constrained networks predict neural activity across the fly visual system / J. K. Lappalainen, F. D. Tschopp, S. Prakhya [et al.] // Nature. – 2024. – Vol. 634, № 8036. – P. 1132–1140. – DOI 10.1038/s41586-024-07939-3.

УДК 004.93'1

КОДИРОВАНИЕ ПРИЗНАКОВ ДИНАМИЧЕСКИХ ДАКТИЛЕМ РУССКОГО ЖЕСТОВОГО ЯЗЫКА ДЛЯ АВТОМАТИЗИРОВАННОГО СРАВНЕНИЯ

Некрасова Д.Р., ORCID 0009-0009-5343-5490,
Лазебная Л.А., канд. техн. наук, ORCID 0000-0003-2442-154X
ФГБОУ ВО «Донецкий национальный технический университет», г. Донецк, РФ
nekrggggh@yandex.ru, l_lazebnay@mail.ru

Введение. Распознавание русского жестового языка (РЖЯ) средствами компьютерного зрения является актуальным направлением автоматической обработки жестовой информации. Важной частью данной задачи является распознавание дактильной азбуки, включающей статические и динамические дактилемы. Для их различения необходимо учитывать не только конфигурацию пальцев, но и движение кисти [1, 2].

Для автоматизированной обработки характеристики дактилем должны быть представлены в формализованном виде. В работе Лаврененко И. С., Филипповича Ю. Н. и Арутюняна М. Г. предложено атрибутивное описание классов дактилем РЖЯ [1]. В исследованиях автоматического распознавания жестов (казахского жестового языка) используются признаки формы и положения руки [3], а извлечение признаков является одним из этапов компьютерного распознавания жестов [4].

Для динамических дактилем важно единообразно представить как конфигурацию пальцев, так и движение кисти [2]. В связи с этим предлагается компактная система признакового описания, позволяющая сопоставлять дактилемы по отдельным характеристикам.

Цель работы – разработать систему кодирования признаков динамических дактилем русского жестового языка и показать возможность их сопоставления на основе полученного кодированного представления.

Основная часть. Для формализованного представления и автоматизированного сравнения дактилем признаки необходимо выразить через систему кодов. Каждому значению признака ставится в соответствие условное обозначение. Система кодирования приведена в таблице.

Таблица

Система кодирования признаков

№	Признак	Возможные значения	Код
1	Количество отдельно расположенных пальцев	0–5	число
1а	Номера отдельно расположенных пальцев	{1,2,3,4,5}	последовательность цифр, например 23

Продолжение таблицы

№	Признак	Возможные значения	Код
1b	Взаимное расположение и состояние отдельно расположенных пальцев	для одного пальца: прямой; согнут дугой; согнут полностью	0; 1; 2
		для двух и более пальцев: прямые; разведены; согнуты от первой фаланги; расположены под прямым углом; оплетён вокруг другого пальца; согнуты в дугу	0; 1; 2; 3; 4; 5 (для каждого пальца через запятую)
2	Количество соединённых пальцев	0–5	число
2a	Номера соединённых пальцев	{1,2,3,4,5}	набор цифр
2b	Состояние соединённых пальцев	согнуты от первой фаланги; прямые; согнутые; соединены в одной точке	0; 1; 2; 3
2c	Отверстие	нет; маленькое; среднее; большое	0; 1; 2; 3
2d	Видимость отверстия	невидимо; видимо; вариативно (зависит от руки человека)	0; 1; 2
3	Сходство с буквой	нет; есть (указать букву)	0; 1 + буква
4	Наблюдаемая часть руки	ладонь закрыта; ладонь открыта; тыльная часть; внешнее ребро	0; 1; 2; 3
5	Направление пальцев	вверх (по умолчанию); вниз; в сторону	0; 1; 2
6	Прижаты ли пальцы	прижаты (по умолчанию); не прижаты	0; 1
7	Динамика	отсутствует; вращение кисти; траекторное движение кончиков пальцев; раскачивание; наклон; перемещение	-; 1; 2; 3; 4; 5 + описание

С помощью данной системы кодирования словесное описание дактилемы преобразуется в структурированную последовательность значений. Для динамики дополнительно сохраняется текстовое описание движения, поскольку одного кода недостаточно для передачи его характера.

Работу системы кодирования рассмотрим на примерах. Значения кодов приведены в порядке признаков, представленном в таблице – 1; 1a; 1b; 2; 2a; 2b; 2c; 2d; 3; 4; 5; 6; 7. В поле 1b допускается несколько кодов через запятую, если группа одновременно обладает ими.

А: нет пальцев, ладонь закрыта, все пальцы прижаты.

Код признаков: 0; –; –; 0; –; –; 0; –; 0; 0; 0; 0; –.

Отдельно расположенных и соединённых пальцев нет, отверстия нет, динамика отсутствует.

Й: отдельно расположены пальцы 4 и 5 – прямые, разведены; пальцы 1, 2 и 3 соединены и согнуты; имеется среднее отверстие; начальная ориентация – тыльная, конечная – ладонная; поворот задаётся в поле динамики; присутствует поворот кисти.

Код признаков: 2; 45; 0,1; 3; 123; 3; 2; 2; 0; 2; 0; 0; 1+тыльная → ладонная.

С: отдельно расположен большой палец, остальные пальцы согнуты; форма кисти визуально напоминает букву «С»; наблюдается ребро ладони; динамика отсутствует.

Код признаков: 1; 1; 0; 4; 2345; 2; 0; –; 1+С; 3; 0; 0; –.

Ъ пара Ь: пальцы 1 и 2 прямые и расположены под прямым углом; ладонь закрыта, остальные пальцы прижаты; присутствует поворот кисти {поворот жеста с ладони на тыльную часть руки или слева направо}.

Код признаков: 2; 12; 0,3; 0; –; –; 0; –; 0; 0; 0; 0; 1+ладонная → тыльная.

Таким образом, одна система кодирования применяется как к статическим, так и к динамическим дактилемам. Совпадение значений признаков указывает на общие характеристики, а различие – на особенности конкретного дактиля. Это позволяет перейти к их сопоставлению по заданным признакам.

Сравним дактилемы А и С. Обе относятся к статическим, у обеих ладонь закрыта и пальцы прижаты, однако различаются поля 1, 1b, 2, 2b, 3 и 4: у А пальцевых групп нет, у С выделяются большой палец и группа согнутых пальцев, а форма кисти напоминает букву «С».

Сравним Й и Ъ. Обе дактилемы динамические, поворот кисти задаётся полем 7. Различаются они полями 1, 1a, 1b, 2, 2a, 2b, 2c, 2d и 4: у Й две пальцевые группы и среднее отверстие, у Ъ – только два прямых пальца под прямым углом. Характер и направление движения также различаются.

Таким образом, одна и та же схема кодирования обеспечивает сопоставимость как статических, так и динамических дактилем.

Заключение. В работе предложена система признакового описания динамических дактилем РЖЯ и их кодированное представление в виде структурированного набора признаков с фиксированным составом полей. Система охватывает конфигурацию пальцев, положение кисти и динамический компонент, что позволяет описывать дактилемы единообразно. Кодированное представление даёт возможность сопоставлять дактилемы по отдельным признакам и может быть использовано для дальнейшей автоматической обработки.

Список литературы

1. Лаврененко, И. С. Формализация классов дактилем русского жестового языка для использования в робототехнических системах типа «робо-рука» / И. С. Лаврененко, Ю. Н. Филиппович, М. Г. Арутюнян // Современные наукоемкие технологии. – 2021. – № 9. – С. 81–85. – URL: https://top-technologies.ru/article/view?id=38820 (дата обращения: 07.10.2026). – ISSN 1812-7320. – DOI 10.17513/snt.38820. – EDN: YIEWMW.
2. Bukva: Russian Sign Language Alphabet / K. Kvanchiani, P. Surovtsev, A. Nagaev, E. Petrova, A. Kapitanov. – 2024. – URL: https://arxiv.org/abs/2410.08675 (дата обращения: 08.10.2026). – Текст: электронный. – DOI 10.48550/arXiv.2410.08675.

3. Amangeldy N. Sign Language Recognition Method Based on Palm Definition Model and Multiple Classification / N. Amangeldy, S. Kudubayeva, A. Kassymova [et al.] // Sensors. – 2022. – Vol. 22, No. 17. – Art. 6621. – DOI 10.3390/s22176621.
4. Qi J. Computer vision-based hand gesture recognition for human-robot interaction: a review / J. Qi, L. Ma, Z. Cui [et al.] // Complex & Intelligent Systems. – 2024. – Vol. 10. – P. 1581–1606. – DOI 10.1007/s40747-023-01173-6.

УДК 004.912:519.76

ЧАСТОТНО-АДАПТИВНАЯ МОДЕЛЬ ОЦЕНКИ СЕМАНТИЧЕСКОЙ БЛИЗОСТИ СЛОВ

Никитенко К.А., ORCID 0009-0000-3595-1592,
Звягинцева А.В., д-р техн. наук, доц., ORCID 0000-0003-2218-9230
ФГБОУ ВО «Донецкий государственный университет», г. Донецк, РФ
kirnik0012@gmail.com, a.zvyagintseva@donnu.ru

Введение. Геометрические меры по распределённым представлениям оценивают семантическую близость слов, но не учитывают напрямую особенности их контекстного употребления [1, 2]. Контекстные модели используют такую информацию, однако при низкой частотности становятся менее надёжными [2].

Цель работы – разработка частотно-адаптивной модели семантической близости, в которой вклад контекстной оценки зависит от объёма доступной статистики.

Основная часть. Геометрический компонент модели строится на распределённом представлении слов: каждой лексеме w соответствует вектор x_w [2]. Для пары слов w_i и w_j значение геометрического сходства определяется косинусной мерой:

$$S^g(w_i, w_j) = \frac{x_{w_i} \cdot x_{w_j}}{\left\|x_{w_i}\right\|\left\|x_{w_j}\right\|}. \quad (1)$$

Величина S^g отражает близость направлений векторов, но не учитывает то, насколько похожи реальные условия употребления слов в текстах. Поэтому геометрическая оценка используется совместно с контекстной характеристикой.

Контекстная часть модели формируется двумя способами. Позиционное представление учитывает содержательные слова в окне ±5 позиций, а синтаксическое – непосредственные зависимости между лексемами. Чтобы часто встречающиеся, но малоинформативные контексты не доминировали в распределении, их веса пересчитываются с помощью PPMI:

$$\mathrm{PPMI}(\mathrm{w},\ c_k)\ = \max\left(0, log_2\left(\frac{N(w,c_k)\cdot N}{N(w)\cdot N(c_k)}\right)\right), \quad (2)$$

где $N(w, c_k)$ – частота совместного появления слова w и контекстного признака c_k; $N(w)$ и $N(c_k)$ – их маргинальные частоты; N – общее число учитываемых совместных появлений. Полученные PPMI-веса преобразуются в вероятностное распределение по контекстам:

$$P(c_k|w) = \frac{PPMI(w,c_k)}{\sum_{j=1}^{|C|} PPMI(w,c_j)}. \quad (3)$$

Поскольку для редких слов такие распределения содержат большое число нулевых значений, перед сравнением применяется аддитивное сглаживание:

$$P_s(c_k|w) = \frac{P(c_k|w)+\varepsilon}{1+\varepsilon\cdot|C|}, \quad (4)$$

где $\varepsilon = 10^{-6}$, а |C| – размер контекстного словаря. Это позволяет исключить строго нулевые вероятности и снизить нестабильность дивергенции при разреженной статистике.

Степень сходства сглаженных контекстных распределений оценивается с помощью дивергенции Дженсена-Шеннона [3]:

$$S^p = 1 - D_{js}. \quad (5)$$

Позиционные и синтаксические контексты дают две независимые вероятностные оценки – $S^p{}_{win}$ и $S^p{}_{dep}$. Для их совместного учёта вводится комбинированная характеристика:

$$S^p{}_{hybrid} = \lambda \cdot S^p{}_{dep} + (1-\lambda)\cdot S^p{}_{win}, \quad (6)$$

где $\lambda \in [0, 1]$ задаёт долю синтаксической составляющей, а $1-\lambda$ – позиционной.

Для пары слов w_i и w_j используется минимальная частота $f_{ij} = \min(f_i, f_j)$, а вес контекстной составляющей задаётся выражением:

$$\beta_{ij} = \beta_{max} \cdot \frac{f_{ij}}{f_{ij}+\tau}. \quad (7)$$

Итоговая оценка вычисляется как

$$S^{adapt}(w_i, w_j) = (1-\beta_{ij})\cdot S^g(w_i, w_j) + \beta_{ij}\cdot S^p{}_{hybrid}(w_i, w_j). \quad (8)$$

Параметры λ, τ и β_{max} подбирались только на обучающей части каждого разбиения 5-кратной кросс-валидации и затем без изменения применялись к тестовой части. Во всех пяти разбиениях оптимальным было $\beta_{max} = 0{,}5$.

Эксперимент проводился на RUSSE HJ, содержащем 398 пар русских слов с экспертными оценками семантической близости [4]. Геометрическая компонента рассчитывалась по 300-мерным векторам Navec [5], контекстная статистика – по SynTagRus [6]. Задача оценки семантической близости слов на русскоязычном материале активно исследуется в последние годы: в частности, в работе [7] предложен бенчмарк ruMTEB, объединяющий задачи семантического сходства текстов и позволяющий сопоставлять различные русскоязычные и мультиязычные модели в единой методологии.

Позиционные признаки формировались в окне ±5 слов, синтаксические – по непосредственным зависимостям между лексемами.

После PPMI-взвешивания, нормировки и сглаживания распределения сравнивались по дивергенции Дженсена-Шеннона. Для совместного анализа использовались 330 пар. Качество измерялось коэффициентом Спирмена, а параметры модели подбирались только на обучающих частях 5-кратной кросс-валидации. Результаты сравнения по частотным группам приведены в таблице.

Таблица

Коэффициент ρ ранговой корреляции Спирмена между модельными и экспертными оценками семантической близости для косинусной и частотно-адаптивной моделей по частотным группам

Частотная группа	Число пар в группе, N	Косинусная мера, ρ	Адаптивная модель, ρ
$f_{ij} < 30$	214	0,7710	0,7520
$30 \leq f_{ij} < 100$	79	0,7553	0,7593
$f_{ij} \geq 100$	37	0,5116	0,5798
Вся выборка (OOF)	330	0,7373	0,7391

Примечание: значения ρ по частотным группам и для всей выборки рассчитаны по OOF-оценке всех разбиений кросс-*валидации; Значение OOF для всей выборки не равно средне-взвешенному по группам т.к. коэффициент Спирмена нелинеен при разбиении на подгруппы.*

Для всей выборки в таблице 1 OOF-оценка составила ρ = 0,7391 для адаптивной и ρ = 0,7373 для косинусной модели. Среднее значение по пяти тестовым фолдам – ρ = 0,7387 ± 0,0745 для адаптивной и ρ = 0,7291 ± 0,0790 для косинусной модели; адаптивная модель превосходила косинусную во всех разбиениях. Эффект зависел от объёма доступной контекстной статистики: для редких слов (f < 30) адаптивная модель уступала косинусной (ρ=0,7520 против 0,7710, что объясняется недостатком статистики для надёжной оценки контекстных распределений; механизм β_{ij} ограничивает, но не устраняет этот эффект), для средних (30 ≤ f < 100) – была сопоставима (0,7593 против 0,7553), а для частых (f ≥ 100) – превосходила её: корреляция увеличилась с 0,5116 до 0,5798 (Δρ = 0,0682), а 95%-й bootstrap-интервал для Δρ, рассчитанный по 20000 итерациям, составил [0,0035; 0,1569].

Заключение. Предложена частотно-адаптивная схема оценки семантической близости, регулирующая вклад контекстной компоненты в зависимости от объёма статистики. В 5-кратной кросс-валидации модель показала более высокую среднюю корреляцию и меньший межфолдовый разброс по сравнению с косинусной мерой. Для частых слов: при f ≥ 100 прирост составил Δρ = 0,0682 при 95% bootstrap-интервале [0,0035; 0,1569].

Список литературы

1. Кузьминов И. Ф. Современные технологии обработки естественного языка для решения задач стратегической аналитики / И. Ф. Кузьминов, П. Д. Бахтин, А. А. Тимофеев [и др.] // Искусственный интеллект и принятие решений. – 2020. – №1. – С. 3–16.

2. Lenci A. Distributional Semantics / A. Lenci, M. Sahlgren. – Cambridge: Cambridge University Press, 2023. – 448 p.
3. Lin J. Divergence Measures Based on the Shannon Entropy / J. Lin // IEEE Transactions on Information Theory. – 1991. – Vol. 37, No. 1. – P. 145–151. – DOI 10.1109/18.61115.
4. Human and Machine Judgements for Russian Semantic Relatedness / A. Panchenko, D. Ustalov, N. Arefyev [et al.] // Analysis of Images, Social Networks and Texts. Springer, 2017. – P. 221–235.
5. Navec: Compact high quality word embeddings for Russian language [Электронный ресурс] / Natasha Project. – URL: https://github.com/natasha/navec (21.09.2026).
6. Дяченко П.В. Современное состояние глубоко аннотированного корпуса текстов русского языка (СинТагРус) / П.В. Дяченко, Л.Л. Иомдин, А.В. Лазурский [и др.] // Национальный корпус русского языка: 10 лет проекту. – Труды Института русского языка им. В.В. Виноградова. – М., 2015. – Вып. 6. – С. 272–299.
7. The Russian-focused embedders' exploration: ruMTEB benchmark and Russian embedding model design / A. Snegirev, M. Tikhonova, A. Maksimova [et al.] // Proceedings of NAACL 2025. – Albuquerque, New Mexico: Association for Computational Linguistics, 2025. – P. 236–254. – DOI 10.18653/v1/2025.naacl-long.12.

УДК 004.85

АЛГОРИТМ ВКЛЮЧЕНИЯ АГРЕГИРОВАННЫХ ОЦЕНОК ТОНАЛЬНОСТИ СООБЩЕНИЙ В МОДЕЛЬ ПРОГНОЗИРОВАНИЯ ДОХОДНОСТИ РОССИЙСКИХ АКЦИЙ

***Никифоров Г.Б.*[1],** ORCID 0009-0002-5152-0383,
***Пименов В.И.*[1,2],** д-р техн. наук, с.н.с., ORCID 0000-0002-7228-3009,
***Андреев Д.А.*[1],** канд. техн. наук, ORCID 0000-0003-2358-8436
[1]ФГБОУ ВО «Псковский государственный университет», г. Псков, РФ
[2]ФГБОУ ВО «Санкт-Петербургский государственный университет промышленных технологий и дизайна», г. Санкт-Петербург, РФ
nikiforov.gb@pskgu.ru, v_pim@mail.ru, d.andreev@pskgu.ru

Введение. Для прогнозирования рыночных показателей применяются модели, объединяющие числовые данные с оценками тональности сообщений. Один из подходов основан на расчёте почасового индекса путём суммирования оценок тональности с учётом релевантности новостей эмитенту [1]. В литературе описана схема преобразования оценок текстов во временные ряды и их использования в прогнозных моделях [2]. При прогнозировании волатильности используются признаки, характеризующие число новостей, их тональность и распределение во времени [3]. В исследованиях российского фондового рынка применяется индекс, объединяющий тональность сообщений с показателями просмотров и реакций аудитории. Эффект включения данного индекса в прогнозные модели зависит от модели и обсуждаемости компаний [4].

Сведение оценок тональности к скалярному индексу [1, 4] приводит к потере информации о соотношении оценок по отдельным классам. Одно

значение индекса может соответствовать различным сочетаниям положительных, нейтральных и отрицательных оценок. В многоуровневой схеме прогнозирования результаты моделей первого уровня могут использоваться как входные признаки модели второго уровня [5]. В данной работе предлагается раздельное суммирование вероятностей трёх классов тональности. Полученные признаки позволяют одновременно учитывать число сообщений и средние вероятности классов и включаются в модель второго уровня совместно с прогнозами моделей первого уровня.

Цель работы – разработка и экспериментальное исследование алгоритма включения агрегированных оценок тональности сообщений в модель прогнозирования доходности российских акций.

Основная часть. Рассматривалась задача прогнозирования доходности российских акций на горизонте шести следующих наблюдаемых часовых торговых интервалов. Доходность рассчитывалась по цене открытия следующего интервала и цене закрытия шестого последующего интервала. Входными данными служили рыночные признаки, прогнозы моделей первого уровня и сообщения, относящиеся к соответствующим акциям.

Предложенный алгоритм:

Шаг 1. Для текущего наблюдаемого часового торгового интервала с началом t_i и завершением $d_i = t_i + 1\text{ч}$ отбираются сообщения с временными метками публикации сообщения $\tau_j \in [t_{i-5}, d_i)$, где t_{i-5} – начало пятого предыдущего часового торгового интервала. Во временное окно сообщений также входят сообщения, опубликованные во время попавших в него перерывов между торгами.

Шаг 2. Модель rubert-tiny2-russian-financial-sentiment [6] оценивает для каждого сообщения вероятности принадлежности к положительному, нейтральному и отрицательному классам тональности $\left(p_j^+, p_j^0, p_j^-\right)$.

Шаг 3. Для акции *a* формируется вектор сумм вероятностей:

$$S_{a,i} = \sum_{j \in M_{a,i}} \left(p_j^+, p_j^0, p_j^-\right),$$

где $M_{a,i}$ – множество индексов сообщений из раздела социальной сети для соответствующей акции в указанном временном окне сообщений. Для пустого временного окна сообщений устанавливается нулевой вектор.

Шаг 4. Три компоненты $S_{a,i}$ дополняют рыночные признаки и прогнозы моделей первого уровня, формируя вход модели второго уровня.

Для экспериментальной оценки использовались часовые котировки российских акций, сообщения из социальной сети для инвесторов «Пульс» и пять прогнозов нейронных сетей LSTM первого уровня. Модель второго уровня обучалась алгоритмом машинного обучения CatBoost от Яндекса. Общий для всех вариантов набор признаков включал 41 рыночный признак, прогнозы первого уровня, циклические признаки часа суток и

биржевой код акции. Обучающая выборка охватывала период с мая по октябрь 2025 г. и содержала 326 352 наблюдения, тестовая – с ноября 2025 г. по апрель 2026 г., при этом содержала 313 742 наблюдения по 198 российским акциям. Для всех сравниваемых алгоритмов использовались одинаковые наблюдения с непустым временным окном сообщений.

На тестовой выборке сопоставлены средняя абсолютная ошибка (MAE), корень из средней квадратичной ошибки (RMSE) и медианная абсолютная ошибка (MedAE) для пяти вариантов признаков (см. таблицу).

Таблица

Ошибки прогнозирования при разных алгоритмах формирования признаков сообщений

Алгоритм формирования признаков сообщений	MAE, п.п.	RMSE, п.п.	MedAE, п.п.
Без признаков сообщений	0,888830	1,285151	0,676823
Только количество сообщений	0,891886	1,291300	0,671142
Средние вероятности	0,852108	1,257354	0,625875
Количество и средние вероятности	0,889369	1,295862	0,661574
Предложенный алгоритм	0,840229	1,243178	0,618051

При использовании предложенного алгоритма получены наименьшие значения всех трёх метрик среди рассмотренных вариантов. По сравнению с вариантом без признаков сообщений MAE, RMSE и MedAE были ниже на 5,47 %, 3,27 % и 8,68 % соответственно. Сумма трёх компонентов вектора равна числу сообщений. Для непустого временного окна сообщений деление компонентов на число сообщений восстанавливает средние вероятности классов. Различия ошибок могут отражать особенности обучения модели на этих представлениях.

Результаты относятся к исследованному периоду и наблюдениям с непустым временным окном сообщений. Статистическая значимость различий ошибок требует проверки, а их снижение не подтверждает улучшения ранжирования или прибыльности торговой стратегии.

Заключение. Предложен алгоритм включения агрегированных оценок тональности сообщений в модель прогнозирования доходности российских акций, отличающийся суммированием вероятностей трёх классов тональности в заданном временном окне сообщений и их использованием моделью второго уровня совместно с рыночными признаками и прогнозами моделей первого уровня, обеспечивающий совместный учёт количества сообщений и их средних вероятностей класса тональности при прогнозировании.

Дальнейшие исследования предполагают проверку устойчивости результатов на новых временных периодах, изучение влияния длительности временного окна и давности сообщений, а также оценку качества ранжирования акций.

Список литературы

1. Khalil, F. Is Deep-Learning and Natural Language Processing Transcending the Financial Forecasting? Investigation Through Lens of News Analytic Process / F. Khalil, G. Pipa //

Computational Economics. – 2022. – Vol. 60, No. 1. – P. 147–171. – DOI 10.1007/s10614-021-10145-2.
2. Ardia, D. The R Package sentometrics to Compute, Aggregate, and Predict with Textual Sentiment / D. Ardia, K. Bluteau, S. Borms [et al.] // Journal of Statistical Software. – 2021. – Vol. 99, No. 2. – P. 1–40. – DOI 10.18637/jss.v099.i02.
3. Caporin, M. Building News Measures from Textual Data and an Application to Volatility Forecasting / M. Caporin, F. Poli // Econometrics. – 2017. – Vol. 5, No. 3. – Art. 35. – DOI 10.3390/econometrics5030035.
4. Хазиев, Г. А. Прогнозирование доходности российских акций на основе анализа сентимента инвесторов в социальных сетях / Г. А. Хазиев, Т. В. Соколова // Экономика и математические методы. – 2025. – Т. 61, № 1. – С. 95–108. – DOI 10.31857/S0424738825010095. – EDN ZQTHHZ.
5. Wolpert, D. H. Stacked Generalization / D. H. Wolpert // Neural Networks. – 1992. – Vol. 5, No. 2. – P. 241–259. – DOI 10.1016/S0893-6080(05)80023-1.
6. mxlcw/rubert-tiny2-russian-financial-sentiment. – Текст: электронный // Hugging Face: сайт. – URL: https://huggingface.co/mxlcw/rubert-tiny2-russian-financial-sentiment (дата обращения: 05.10.2026).

УДК 004. 159.923:159.942.5

РАЗРАБОТКА ТЕОРЕТИЧЕСКИХ ОСНОВ И КОМПЬЮТЕРНЫХ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ ДИАГНОСТИРОВАНИЯ ПСИХОЭМОЦИОНАЛЬНОГО СОСТОЯНИЯ ЛИЧНОСТИ ВО ВРЕМЯ СТРЕССА ВОЕННОГО ВРЕМЕНИ

Пигуз В.Н., ORCID 0009-0003-3968-3144,
Изосимова С.А., ORCID 0000-0002-1521-5579,
Ивашко К.С., ORCID 0000-0002-0195-2279,
Ковалева К.В., ORCID 0009-0002-8218-1898,
Коваленко И.М., Сальников Р.И.
ФГБНУ «Институт проблем искусственного интеллекта», г. Донецк, РФ
izosimova.snezhan@mail.ru

Введение. Постановка проблемы. Психологические проблемы уволенных в запас военнослужащих, а также мирных жителей, пострадавших в результате военных действий, приобретают острую актуальность не только в специализированной литературе психологической тематики, но и в разноплановых средствах массовой информации (далее СМИ). Посттравматическое стрессовое расстройство (далее ПТСР) – «…тяжелое психическое состояние, возникающее в результате единичного или повторяющихся событий, оказывающих сверхмощное негативное воздействие на психику индивида. Травматичность события тесно связана с ощущением собственной беспомощности из-за невозможности эффективно действовать в опасной ситуации» [1] прочно обосновался на

отечественной ниве. В международных классификаторах болезней ПТСР рассматривается как психическое расстройство. Во второй половине 20 века ПТСР диагностировался преимущественно у людей, принимавших участие, либо переживших боевые действия. В результате чего ПТСР стал называться «специфическим военным расстройством», «психонейроз военного времени», «военный невроз», «синдромом военного сердца» и т.п. Тенденция диагностики и лечения ПТСР совершенствовалась и разрабатывалась, что нашло свое воплощение в научных учреждениях, открытых на территории РФ в 1990-х гг.: «лаборатория посттравматического стресса и психотерапии при Институте психологии РАН; лаборатория при Академии управления МВД; психологическое общество травматического стресса» [2].

Поэтому разработка безмедикаментозных методов выявления, коррекции и терапии такого рода нарушений является одной из центральных проблем современной психологической науки и практики. Что позволит предотвратить негативные психологические последствия, возникшие у человека под влиянием ситуации военных действий, до начала развития симптомов, путем безмедикаментозной интеллектуальной терапии (психологического тренинга), повышающей сопротивляемость психики развитию негативных последствий пребывания в зоне военного конфликта. Что является основой НИР ФГБНУ «Институт проблем искусственного интеллекта», проводимой в 2023 и текущем году.

Наиболее полно проблема полноценного функционирования эмоциональной сферы психики человека в экстремальных условиях активно разрабатывается и анализируется в рамках авиационно-космической, военной психологии, акмеологии, психологии экстремальных ситуаций в работах: Г.Т. Береговой, В.А. Бодров, Л.П. Гримак, Л.А. Китаев-Смык, В.И. Лебедев, В.А. Пономаренко, Л.С. Хачатурьянц, В.М. Ахутин, А. Кемпински, Н. Коупленд, Е.О. Лазебная, Б.Ф. Маклаков, В.А. Пухов, С.В. Чермянин, Е.Б. Шустов, Ю.А. Александровский, Ф.Е. Василюк, Лобастов, Пергаменщик, Л.И. Спивак [3]. Однако все эти работы объединяет тот аспект, что они посвящены нейтрализации последствий сформировавшегося и оформившегося у человека ПТСР. Проблему организации профилактических мер, тем более безмедикаментозного характера, которые повышают сопротивляемость психики последствиям эмоционального стресса, практически никто из вышеперечисленных исследователей не рассматривает.

Цель исследования – формирование теоретической экспериментальной базы, а также разработка компьютерного комплекса, для организации психологических мер для диагностики и безмедикаментозной коррекции негативных изменений, вызванных военным стрессом в эмоционально-волевой личностной сфере, как у военнослужащих, так и у мирного населения.

Объект исследования – эмоционально-волевые особенности личности, находящейся в зоне локальных военных действий, влияющие на нейтрализацию развития ПТСР.

Предмет исследования – интеллектуальная безмедикаментозная компьютерная терапия нейтрализации развития ПТСР, проявляющегося в форме негативных изменений в эмоционально-волевой сфере личности.

Практическая значимость работы. В основе НИР – экспериментальный метод исследования – метод срезов. Также использован статистический метод дисперсионного анализа, разработанный К. Пирсоном, для определения различного рода психологических зависимостей и фобий, вызванных различными типами стрессов военного времени.

Выводы. Применение разрабатываемой компьютерной системы в профилактических целях позволит сформировать психологическую готовность личности к саморегуляции индивидуального психоэмоционального состояния как в повседневной жизни, так и в ситуации ЧС. Что особенно актуально для военнослужащих перед отправкой в зону военного конфликта, и позволит своевременно предупредить развитие синдромов ПТСР в психоэмоциональной сфере, а именно: синдрома эмоционального выгорания; повышения уровня тревожности (ситуативной и личностной); снижения уровня социальной адаптации и т.п.

Работа выполнена в рамках научной темы «Разработка теоретических основ и компьютерных интеллектуальных технологий диагностирования и безмедикаментозной саморегуляции психоэмоциональных состояний личности» (регистрационный номер FREN-2024-0003), проводимой сотрудниками Института проблем искусственного интеллекта в 2026 г.

Список литературы

1. Сальников И. С. Определение речевых особенностей и функциональных характеристик словесных текстов, используемых при саморегуляции психоэмоциональных состояний личности – компьютерно-информационный аспект / И. С. Сальников, С. А. Изосимова, В. Н. Пигуз, К. С. Ивашко. Математическая психология: современное состояние и перспективы: материалы научной конференции по математической психологии, посвященной 90-летию В.Ю. Крылова (26-27 октября 2023 г.). Отделение общественных наук РАН. Федеральное государственное бюджетное учреждение науки. Институт психологии Российской академии наук (ИП РАН). – Москва, РФ. – 2023.
2. Сальников И. С. Исследование эффективного использования безмедикаментозных методов и средств интеллектуально-духовной терапии и прагматических особенностей искусственного эмоционального интеллекта для целей саморегуляции психоэмоциональных состояний личности / И. С. Сальников, С.А. Изосимова, В. Н. Пигуз, К. С. Ивашко. Донецкие чтения 2023: образование, наука, инновации, культура и вызовы современности : материалы VIII Международной научной конференции (Донецк, 25–27 октября 2023 г.). – Том 2: Физические, технические и компьютерные науки / под общей редакцией проф. С.В. Беспаловой. – Донецк: Изд-во ДонГУ, 2023. – С. 352–354.
3. Сальников И. С. Описание системы вербальной терапии и саморегуляции психофизиологических состояний личности / И. С. Сальников, Р. И. Сальников,

Т. Д. Клюшанова. Искусственный интеллект: теоретические аспекты, практическое применение: материалы Донецкого международного научного круглого стола. – Донецк: ФГБНУ «ИПИИ», 2023. – С. 192–196.
4. Сальников И. С. Программный комплекс поддержания и обслуживания информационной системы / И. С. Сальников, Р. И. Сальников, Т. Д. Клюшанова. Искусственный интеллект: теоретические аспекты, практическое применение: материалы Донецкого международного научного круглого стола. – Донецк: ФГБНУ «ИПИИ», 2023. – С. 197–201.

УДК 681.5

УНИФИЦИРОВАННЫЙ ИНТЕРФЕЙС МОДУЛЕЙ КАК ОСНОВА МАСШТАБИРУЕМОЙ АРХИТЕКТУРЫ ИНФОРМАЦИОННОГО ОБЕСПЕЧЕНИЯ СИСТЕМ КОНТРОЛЯ ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ

Пресняков М.С., ORCID 0009-0003-3374-265X,
Прибыльский А.В., канд. техн. наук, доц., ORCID 0000-0003-0834-0782
ФГАОУ ВО «Южный федеральный университет», г. Таганрог, РФ
mpresniakov@sfedu.ru, apribylsky@sfedu.ru

Введение. Цифровой двойник по ГОСТ Р 57700.37–2021 представляет собой цифровую модель объекта, связанную с ним двусторонними информационными связями [1]. В производстве по степени автоматизации обмена данными различают цифровую модель, цифровую тень и цифровой двойник [2]. Построению двойника предприятия мешает то, что его информационное обеспечение (далее ИО) обычно состоит из программ, связанных напрямую, и замена любого компонента, в том числе реального источника данных его моделью, требует доработки соседних, а стоимость расширения растёт с каждым новым модулем. Д. Парнас показал, что качество разбиения системы на модули определяется тем, какие решения каждый модуль скрывает от остальных [3]. В работе этот принцип применяется к ИО предприятия, модули которого распределены по уровням управления [4] и обмениваются данными в реальном времени.

Цель работы – обоснование принципов модульной архитектуры ИО, позволяющей построить укрупнённую имитационную модель цифрового двойника технологического предприятия и настроить её параметры до подключения реального оборудования.

Основная часть. Первый принцип – единый контракт модуля. Модуль описывается не набором связей с другими модулями, а типами данных, которые он принимает и публикует:

$$m = \langle T^{in}, T^{out}, P \rangle, \quad (1)$$

где T^{in} – множество типов входящих сообщений, на которые модуль подписан; T^{out} – множество публикуемых типов; P – параметры конфигурации. Модуль не хранит адресов других модулей, поэтому их состав может меняться без его изменения.

Второй принцип – единый формат сообщения для всех классов данных:

$$s = \langle id, t, type, v, unit, zone, st, src \rangle, \tag{2}$$

где id – идентификатор параметра, t – временная метка, $type$ – тип сообщения с номером версии, v – значение, $unit$ – единица измерения, $zone$ – участок технологической линии, st – состояние («норма», «предупреждение», «авария»), src – источник. Номер версии позволяет развивать формат, не нарушая работу старых подписчиков.

Третий принцип – обмен через брокер по модели «публикация – подписка», при которой издатель не знает подписчиков и не блокируется при их отказе [7]. В качестве протокола выбран MQTT с иерархией тем и тремя уровнями гарантии доставки для разных типов сообщений [6]. Темы строятся по структуре «линия → участок → оборудование → параметр», согласованной с иерархией оборудования по ГОСТ Р МЭК 62264-1 [4].

Четвёртый принцип – взаимозаменяемость реального модуля и его имитационной модели. Модуль m^{sim} может заменить модуль m^{real}, если их контракты (1) совпадают:

$$T_{sim}^{\ in} = T_{real}^{\ in}, \quad T_{sim}^{\ out} = T_{real}^{\ out}. \tag{3}$$

Тогда ИО предприятия описывается набором модулей $D = \{m_1^{\sigma 1}, \ldots, m_n^{\sigma n}\}$, где $\sigma_i \in \{\text{sim}, \text{real}\}$ указывает, представлен модуль реальным компонентом или имитационной моделью. При всех $\sigma_i = \text{sim}$ система является цифровой моделью предприятия, при реальных источниках данных и одностороннем обмене – цифровой тенью, а при передаче управляющих команд обратно на оборудование – цифровым двойником [2].

Имитационное моделирование на стадии цифровой модели позволяет до внедрения настроить интенсивность сообщений, уровни гарантии доставки, пороги предупреждений, нагрузку на брокер и реакцию на аварийные сценарии [5]. Эффект модульности оценивается двумя показателями. Число поддерживаемых интерфейсов в системе из n модулей при прямых связях в худшем случае и при обмене через брокер составляет

$$N_{\text{пр}} = n(n-1)/2, \quad N_{\text{бр}} = n. \tag{4}$$

Локальность изменений характеризует коэффициент

$$K_i = |\Delta_i| \,/\, (n-1), \tag{5}$$

где Δ_i – множество модулей, которые требуется изменить при замене модуля m_i на модуль с тем же контрактом. Для архитектуры, удовлетворяющей принципам, $K_i = 0$ для любого модуля, кроме брокера.

Принципы применены к укрупнённой модели линии розлива жидкой пищевой продукции. Модули образуют пять классов: источники данных, транспорт, хранение, обработка и представление. Источники на стадии

модели заменены имитатором линии, который публикует сообщения формата (2) по сценариям нормальной работы, нехватки тары, затора на выходе и останова наполнителя. Сценарии задаются параметрами имитатора, поэтому модель воспроизводит и штатную работу линии, и редкие аварийные ситуации, которые на действующем производстве намеренно создать нельзя. Для 10 модулей прямые связи в худшем случае дают 45 интерфейсов, обмен через брокер – 10. В варианте с прямой интеграцией замена базы данных SQLite на MySQL затрагивала источник, интерфейс оператора и классификатор (K = 3/9 ≈ 0,33), в модульном варианте меняется только модуль хранения (K = 0).

Платой за слабую связанность являются задержка на брокере и единая точка отказа. Поэтому контуры, требующие реакции за единицы миллисекунд, остаются на уровне контроллера, брокер резервируется, а допустимость задержек при заданной интенсивности потоков проверяется на имитационной модели ещё до подключения оборудования.

Заключение. Единый контракт модуля, единый формат сообщения, обмен через брокер и взаимозаменяемость реальных и имитационных модулей позволяют рассматривать ИО технологического предприятия как укрупнённую модель его цифрового двойника. Модель настраивается средствами имитационного моделирования и поэтапно переводится на реальное оборудование без переработки архитектуры. Дальнейшая работа связана с исследованием на имитационной модели задержек и пропускной способности брокера при росте числа источников данных.

Список литературы

1. ГОСТ Р 57700.37–2021. Компьютерные модели и моделирование. Цифровые двойники изделий. Общие положения: национальный стандарт Российской Федерации: утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии от 16 сентября 2021 г. № 979-ст: введен впервые : дата введения 2022-01-01. – URL: https://meganorm.ru/mega_doc/norm/gost-r_gosudarstvennyj-standart/10/gost_r_57700_37-2021_natsionalnyy_standart_rossiyskoy.html (дата обращения: 08.10.2026). – Текст: электронный.
2. Digital Twin in manufacturing: A categorical literature review and classification / W. Kritzinger, M. Karner, G. Traar [и др.] // IFAC-PapersOnLine. – 2018. – Vol. 51, № 11. – P. 1016–1022. – Текст: непосредственный. – DOI 10.1016/j.ifacol.2018.08.474.
3. Parnas, D. L. On the criteria to be used in decomposing systems into modules / D. L. Parnas // Communications of the ACM. – 1972. – Vol. 15, № 12. – P. 1053–1058. – Текст: непосредственный. DOI 10.1145/361598.361623.
4. ГОСТ Р МЭК 62264-1–2014. Интеграция систем управления предприятием. Часть 1. Модели и терминология: национальный стандарт Российской Федерации: утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии от 26 ноября 2014 г. № 1874-ст: введен взамен ГОСТ Р МЭК 62264-1–2010: дата введения 2016-01-01. – URL: https://meganorm.ru/Index/59/59147.htm (дата обращения: 08.10.2026). – Текст: электронный.

5. Кобелев, Н. Б. Имитационное моделирование : учебное пособие / Н. Б. Кобелев, В. А. Половников, В. В. Девятков; под общ. ред. Н. Б. Кобелева. – Москва: КУРС: ИНФРА-М, 2013. – 368 с. – Текст: непосредственный. – ISBN 978-5-905554-17-9.
6. MQTT Version 5.0: OASIS Standard / ed. by A. Banks, E. Briggs, K. Borgendale, R. Gupta. – 2019. – 7 March. – Текст: электронный. – URL: https://docs.oasis-open.org/mqtt/mqtt/v5.0/mqtt-v5.0.html (дата обращения: 08.10.2026).
7. The many faces of publish/subscribe / P. Th. Eugster, P. A. Felber, R. Guerraoui, A.-M. Kermarrec // ACM Computing Surveys. – 2003. – Vol. 35, № 2. – P. 114–131. – Текст: непосредственный. – DOI 10.1145/857076.857078.

УДК 004.8

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ ПРОМПТ-ИНЖИНИРИНГА ПРИ РЕШЕНИИ ЗАДАЧ БОЛЬШИМИ ЯЗЫКОВЫМИ МОДЕЛЯМИ

Сахаров Р.И., ORCID 0009-0001-4813-4732,
Шипшова О.А., канд. экон. наук, доц., ORCID 0000-0003-1670-4064
ФГБОУ ВО «Казанский национальный исследовательский технический университет – Казанский авиационный институт им. А. Н. Туполева», г. Казань, РФ
saxarovrom@yandex.ru, os69@bk.ru

Введение. Большие языковые модели призваны решать широкий круг задач обработки естественного языка, включая классификацию, ответы на вопросы, преобразование текста и задачи рассуждения. При этом, качество результата зависит не только от параметров модели, но и от содержания и структуры запроса. В статье рассматриваются подходы к промтингу предложенные некоторыми экспертами. Так, Т. Браун с соавторами продемонстрировал способность GPT-3 выполнять новые задачи по инструкции и набору примеров без обновления параметров [1]. В дальнейшем, этот подход многошагового рассуждения был развит Дж. Вэйем [2], и С. Ваном [3]. В работах П. Саху [4], Ш. Ватсала и Х. Дубея [5], а также Я.-Я. Лю [6] систематизированы методы промптинга, при этом авторы показывают, что их эффективность определяется типом задачи, особенностями модели и допустимыми вычислительными затратами.

Цель работы – сравнить четыре распространенных метода промпт-инжиниринга по принципу действия, рациональной области применения и ограничениям.

Основная часть. Промпт-инжиниринг представляет собой проектирование содержания и структуры запроса для получения требуемого поведения предварительно обученной модели. Промпт может включать инструкцию, контекст, примеры решения и требования к форме ответа. В отличие от дообучения параметры модели не изменяются, поэтому способ не

требует отдельного цикла обучения. Управление результатом достигается информацией, переданной в текущем контексте [4, 6].

Промптинг без примеров (Zero-shot prompting) содержит описание задачи без демонстраций решения. По Т. Брауну и соавторам [1], модель опирается на знания и закономерности, полученные при предварительном обучении. Преимущества метода состоят в простоте и экономии контекста. Он подходит для четко сформулированных задач и первичной проверки возможностей модели. Основное ограничение – высокая чувствительность к полноте и однозначности инструкции.

Промптинг с несколькими примерами (few-shot prompting) дополняет инструкцию образцами вида «входные данные – правильный результат». Демонстрации задают локальный шаблон выполнения задачи без изменения параметров модели [1]. Подход полезен, когда требуется показать формат ответа, правило классификации или способ преобразования данных. Ш. Ватсал и Х. Дубей отмечают зависимость результата от качества и репрезентативности примеров [5]. Кроме того, демонстрации занимают часть доступного контекста.

Промптинг с цепочкой рассуждений (Chain-of-Thought, CoT) вводит промежуточные шаги между условием и итоговым ответом. Дж. Вэй и соавторы предложили включать в демонстрации не только результат, но и последовательность решения [2]. Эксперименты на трех крупных языковых моделях показали улучшение в арифметических, символических и логических задачах. Восемь CoT-демонстраций для PaLM с 540 млрд параметров позволили превзойти сравниваемый вариант GPT-3 на наборе GSM8K. Метод целесообразен для многошаговых задач, но в простой классификации или извлечении информации лишь увеличивает длину запроса и ответа.

Самосогласованность (Self-Consistency) является стратегией декодирования поверх CoT. Модель генерирует несколько различающихся цепочек рассуждений, после чего выбирается наиболее согласованный ответ. В экспериментах С. Ван и соавторов точность выросла на 17,9 процентного пункта на GSM8K, на 11,0 пункта на SVAMP, на 12,2 пункта на AQuA, на 6,4 пункта на StrategyQA и на 3,9 пункта на ARC-challenge [3]. Метод снижает зависимость результата от единственной траектории, но требует дополнительных генераций, времени и вычислительных ресурсов.

Сопоставление методов показывает, что они решают разные проблемы и не образуют единой шкалы эффективности. Zero-shot минимизирует подготовку запроса, few-shot уточняет требуемый образец, CoT организует многошаговое решение, а Self-Consistency повышает его устойчивость. Выбор следует связывать с причиной ошибки: при непонимании формата добавлять примеры, при нарушении последовательности операций переходить к CoT, а несколько траекторий использовать при нестабильных ответах. Рационально начинать с простой инструкции и усложнять запрос

лишь тогда, когда прирост качества оправдывает увеличение контекста, времени обработки и стоимости генерации [4–6].

Таблица

Сравнение методов промпт-инжиниринга (составлено автором)

Метод	Основной принцип	Рациональное применение	Основное ограничение
Без примеров	Инструкция	Четкие задачи	Зависимость от формулировки
С примерами	Инструкция и образцы	Формат и правила	Подбор примеров
Цепочка рассуждений	Промежуточные шаги	Многошаговые задачи	Длина запроса и ответа
Самосогласованность	Несколько цепочек	Сложные рассуждения	Дополнительные генерации

Таблица составлена по результатам работ [1–6].

Заключение. Универсального метода промпт-инжиниринга не существует. Для четко заданной задачи обычно достаточно zero-shot. Few-shot нужен, когда важен образец ответа или нестандартное правило. CoT целесообразен при содержательно необходимом многошаговом рассуждении, а Self-Consistency – когда устойчивость результата оправдывает дополнительные вычисления. Эти методы не исключают друг друга: примеры могут содержать цепочки рассуждений, а самосогласованность может применяться к нескольким CoT-траекториям. Однако каждое усложнение должно устранять конкретную проблему, а не использоваться по умолчанию. Следовательно, выбор метода должен учитывать тип задачи, свойства модели, качество доступных примеров и ограничения по времени, объему контекста и вычислительным ресурсам. При практическом сравнении следует сохранять одинаковые настройки модели и набор заданий, оценивая не только точность, но и устойчивость ответа, длину запроса и число генераций. Это позволяет отделить влияние метода от особенностей модели и сделать выбор воспроизводимым.

Список литературы

1. Language Models are Few-Shot Learners / T. B. Brown, B. Mann, N. Ryder [et al.] // Advances in Neural Information Processing Systems. – 2020. – Vol. 33. – P. 1877–1901. – URL: https://arxiv.org/abs/2005.14165 (дата обращения: 17.09.2026).
2. Chain-of-Thought Prompting Elicits Reasoning in Large Language Models / J. Wei, X. Wang, D. Schuurmans [et al.] // Advances in Neural Information Processing Systems. – 2022. – Vol. 35. – P. 24824–24837. – URL: https://doi.org/10.52202/068431-1800 (дата обращения: 17.09.2026).
3. Self-Consistency Improves Chain of Thought Reasoning in Language Models / X. Wang, J. Wei, D. Schuurmans [et al.] // The Eleventh International Conference on Learning Representations. – 2023. – URL: https://openreview.net/forum?id=1PL1NIMMrw (дата обращения: 17.09.2026).
4. A Systematic Survey of Prompt Engineering in Large Language Models: Techniques and Applications / P. Sahoo, A. K. Singh, S. Saha [et al.] // arXiv. – 2024. – URL: https://doi.org/10.48550/arXiv.2402.07927 (дата обращения: 17.09.2026).

5. Vatsal, S. A Survey of Prompt Engineering Methods in Large Language Models for Different NLP Tasks / S. Vatsal, H. Dubey // arXiv. – 2024. – URL: https://doi.org/10.48550/arXiv.2407.12994 (дата обращения: 17.09.2026).
6. A Comprehensive Taxonomy of Prompt Engineering Techniques for Large Language Models / Y.-Y. Liu, Z. Zheng, F. Zhang [et al.] // Frontiers of Computer Science. – 2026. – Vol. 20. – Art. 2003601. – URL: https://doi.org/10.1007/s11704-025-50058-z (дата обращения: 17.09.2026).

УДК 622.276

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ НЕФТЕГАЗОВОГО ОБОРУДОВАНИЯ

Сулейманов Д.А., ORCID 0009-0007-8788-9672,
Сементеева Л.Ш., доц.,ORCID 0000-0002-5227-7218
ФГБОУ ВО «Уфимский государственный нефтяной технический университет»,
г. Уфа, РФ
info@rusoil.net

Введение. Современное развитие нефтегазовой отрасли требует внедрения интеллектуальных систем диагностики и прогнозирования отказов оборудования. В УГНТУ разработаны датчики контроля состояния агрегатов по вибрации и анализу масла, однако задача прогнозирования отказов на их основе остается актуальной [1]. Внезапные отказы приводят к значительным экономическим потерям и экологическим рискам. По данным исследований, до 30 % внеплановых остановок производств связаны с отказами оборудования, которые можно было предотвратить при своевременном обнаружении предотказных состояний. Особую актуальность задача приобретает для газоперекачивающих агрегатов, где стоимость одного часа простоя может достигать сотен тысяч рублей, а аварийные ситуации сопряжены с риском разлива углеводородов.

Цель работы – разработка подхода к прогнозированию отказов нефтегазового оборудования на основе методов машинного обучения с использованием данных вибродиагностики и контроля состояния смазочных материалов.

Основная часть. Прогнозирование технического состояния базируется на анализе временных рядов параметров: вибрационных характеристик, концентрации металлов в масле, температуры, давления и других эксплуатационных показателей. Традиционные методы, основанные на физических моделях износа, требуют большого объема данных для калибровки. Методы машинного обучения позволяют выявлять сложные закономерности без явного задания моделей процессов.

Входными параметрами системы являются: результаты вибромониторинга (среднеквадратичные значения виброскорости, спектральные характеристики); данные спектрального анализа масла (концентрации металлов – железо, хром, алюминий, вязкость, кислотное число); эксплуатационные параметры (температура подшипников, давление масла, нагрузка, частота вращения); история плановых ремонтов и замен деталей. Дополнительно формируются производные признаки: скорость нарастания концентрации металлов, тренды вибрационных характеристик и отношения спектральных компонент.

Для решения задачи предлагаются следующие методы машинного обучения:

1. Рекуррентные нейронные сети (LSTM) – для моделирования долговременных зависимостей в данных [2]. LSTM-сети обладают способностью сохранять информацию на длительных промежутках времени, что особенно важно при анализе медленно развивающихся процессов деградации. Позволяют прогнозировать отказы за 48 часов с точностью до 92 %.

2. Градиентный бустинг (XGBoost) – для классификации состояния оборудования по набору признаков [3]. Данный метод является одним из наиболее эффективных для задач классификации с табличными данными, демонстрируя высокую точность и устойчивость к переобучению. Эффективен для краткосрочного прогнозирования (8-12 часов) с точностью 87 %.

3. Методы обнаружения аномалий (Autoencoder) – для выявления отклонений от нормального режима [4]. Autoencoder представляет собой нейронную сеть, обученную восстанавливать входные сигналы с минимальной ошибкой для нормальных данных. При появлении аномального сигнала ошибка восстановления резко возрастает, что позволяет сигнализировать о потенциальной проблеме. Позволяют выявлять предотказные состояния за 100-200 часов. Наибольший практический эффект достигается при объединении моделей в ансамбль, где LSTM обеспечивает долгосрочный прогноз, XGBoost – краткосрочную классификацию, а Autoencoder – раннее обнаружение аномалий.

Предложена трехуровневая архитектура системы: сбор и обработка данных (удаление выбросов, заполнение пропусков, синхронизация); выделение признаков и обучение моделей (извлечение статистических и частотных характеристик, оптимизация гиперпараметров); принятие решений и выдача рекомендаций (прогноз вероятности отказа, формирование рекомендаций по обслуживанию).

Экспериментальное исследование проведено на базе данных работы газоперекачивающих агрегатов (2020-2025 гг., 47 отказов различных типов: повреждения подшипников, износ зубчатых передач, трещины в корпусах). Данные разделены на обучающую (70 %), валидационную

(15 %) и тестовую (15 %) выборки с разделением по времени для исключения утечки информации. Результаты: LSTM – точность 92 % за 48 часов (чувствительность 89 %, специфичность 95 %); XGBoost – 87 % за 8-12 часов (F1-мера 0.86); комбинированный подход (LSTM+XGBoost) – 94 % с снижением ложных тревог на 42 %. Наиболее информативные признаки: скорость нарастания концентрации железа в масле, изменение спектра вибрации 500-1000 Гц, скорость изменения температуры подшипников, изменение вязкости масла.

Экономическая эффективность: экономия от предотвращения внеплановых простоев – 12-15 млн руб./год на один агрегат средней мощности, окупаемость – 1-2 года. Технические требования: частота дискретизации не менее 500 Гц, спектроанализаторы масла, GPU-ускорители для LSTM, каналы связи от 100 Мбит/с. Следует учитывать, что предложенный подход чувствителен к полноте обучающей выборки и требует формирования представительного набора данных по каждому типу оборудования.

Заключение. Предложенный подход повышает эффективность прогнозирования отказов и может быть интегрирован в существующие системы. Перспективные направления: интеграция с цифровыми двойниками, разработка гибридных моделей, создание универсальной платформы для предиктивной аналитики. Разработанный подход может найти применение в энергетике, металлургии и химической промышленности.

Список литературы

1. Имаев Д. Р. Искусственный интеллект в нефтегазовой отрасли: автоматизация и повышение эффективности / Д. Р. Имаев, В. А. Соколов, Л. Ш. Сементеева // Студенческий форум. – 2025. – № 21(330). – URL: https://nauchforum.ru/journal/stud/330/174272.
2. Смирнов П. А. Применение рекуррентных нейронных сетей для прогнозирования технического состояния оборудования / П. А. Смирнов, А. В. Петров // Информационные технологии в промышленности. – 2024. – Т. 12, № 3. – С. 45–53. – DOI 10.25206/2588-0373-2024-12-3-45-53.
3. Кузнецов В. Г. Методы градиентного бустинга в задачах диагностики нефтегазового оборудования / В. Г. Кузнецов, Д. И. Соколов // Вестник УГНТУ. Серия: Информатика и управление. – 2025. – № 2. – С. 78–86.
4. Григорьева Е. А. Обнаружение аномалий в данных вибромониторинга с использованием автоэнкодеров / Е. А. Григорьева, А. А. Лебедев // Проблемы машиностроения и надежности машин. – 2024. – № 4. – С. 112–119.

УДК 331.54+004.8

ЧЕЛОВЕЧЕСКИЙ КАПИТАЛ В ЭПОХУ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА (ИИ): ПЕРЕОСМЫСЛЕНИЕ НАВЫКОВ И КОМПЕТЕНЦИЙ

Сычёва И.И., ORCID 0009-0007-6260-3172
Рыбницкий филиал ГОУ «Приднестровский государственный университет им. Т.Г. Шевченко», г. Рыбница, Приднестровье
irinkam86@mail.ru

Введение. Мировая экономика переживает серьезные изменения, которые радикально трансформируют характер труда и способы его организации. Основным драйвером этих изменений выступают технологии искусственного интеллекта (ИИ), машинного обучения, робототехники и анализа больших данных. В отличие от предыдущих промышленных революций, искусственный интеллект затрагивает не только физический труд, но и когнитивные процессы, рутинные и нерутинные виды деятельности практически во всех секторах экономики.

Согласно прогнозу Всемирного экономического форума, к 2027 году в мире будет утрачено около 83 миллионов рабочих мест и создано 69 миллионов новых. Таким образом, ожидается чистое сокращение занятости примерно на 14 миллионов рабочих мест вследствие технологических изменений [1]. Основная задача экономики заключается уже не в создании новых рабочих мест, а в переосмыслении самого понятия профессиональной компетентности.

Цель исследования – проанализировать и оценить, каким образом революция в области искусственного интеллекта изменяет содержание человеческого капитала.

Основная часть. Искусственный интеллект не просто заменяет человека, а меняет структуру спроса на его способности. Особую ценность приобретают высшие когнитивные и социально-эмоциональные навыки, тогда как значение рутинных технических компетенций постепенно снижается.

Воздействие ИИ на занятость можно охарактеризовать как процесс «созидательного разрушения», при котором одни профессии исчезают, другие возникают, а большинство существенно трансформируется. Наибольшему риску подвержены профессии, связанные с предсказуемыми физическими действиями, обработкой данных и выполнением рутинных когнитивных операций. В то же время ИИ способствует появлению совершенно новых категорий профессий и формирует спрос на специалистов, обладающих глубокими техническими знаниями. Главным следствием становится существенное изменение структуры компетенций, необходимых для успешной карьеры.

Таблица 1

Примеры профессий с различным потенциалом автоматизации

Потенциал автоматизации	**Профессии**	**Причина**
Высокий	Операторы ввода данных, рабочие конвейерных линий, банковские кассиры, продавцы-кассиры	Повторяющиеся операции, работа со структурированными данными
Средний	Продавцы-консультанты, водители, производственные рабочие, бухгалтеры	Сочетание рутинных и нерутинных задач
Низкий	Руководители компаний, разработчики программного обеспечения, медицинские работники, преподаватели, художники	Требуются творчество, стратегическое мышление, сложное решение проблем и эмоциональный интеллект

Источник: Future of Jobs Report (2023)

Спрос на экспертов в области ИИ и машинного обучения (ML), специалистов по работе с данными (data scientists), инженеров-робототехников и аналитиков по кибербезопасности достиг исторического максимума. Кроме того, возникают профессии, непосредственно связанные с применением ИИ, – например, менеджеры продуктов на базе ИИ, специалисты по этике ИИ и др.

Таблица 2

Наиболее востребованные профессии эпохи ИИ

Профессия	**Основная функция**	**Прогнозируемый рост**
Специалист по ИИ и машинному обучению	Разработка моделей машинного обучения	35-40 %
Data Scientist	Анализ данных и поддержка принятия решений	30-35 %
Инженер-робототехник	Проектирование роботизированных систем	25-30 %
Специалист по кибербезопасности	Защита информационных систем	28-32 %
Инженер по автоматизации	Внедрение автоматизированных процессов	20-25 %
Специалист по этике ИИ	Контроль справедливости и прозрачности ИИ-систем	Новая профессия
Специалисты с сочетанием цифровых и гибких навыков	Работа в различных отраслях	Более 15 %

Источник: Future of Jobs Report (2023)

На основе анализа отраслевых исследований [2] выделены четыре ключевые группы компетенций будущего:

1. Грамотность в области ИИ и цифровых технологий (понимание принципов работы ИИ, знание возможностей и ограничений интеллек-

туальных систем, умение использовать ИИ-инструменты в профессиональной деятельности).

2. Когнитивные навыки высокого уровня (критическое мышление, творчество и креативность, когнитивная гибкость). Именно в этих областях человек сохраняет преимущество перед ИИ.

3. Социально-эмоциональные навыки (эмоциональный интеллект, коммуникация и сотрудничество, лидерство). По мере автоматизации технических функций значение этих навыков возрастает.

4. Адаптивность и непрерывное обучение (способность быстро обучаться, устойчивость к изменениям и стрессам). Это метакомпетенция, обеспечивающая развитие всех остальных навыков.

Заключение. Эпоха искусственного интеллекта знаменует собой глубокую трансформацию характера труда и содержания человеческого капитала. Если существующая система подготовки кадров останется неизменной, мировая экономика может столкнуться с масштабной технологической безработицей. Будущее будет принадлежать не тем, кто конкурирует с машинами в выполнении рутинных операций, а тем, кто способен творчески мыслить, критически анализировать информацию, сотрудничать и проявлять эмпатию.

Успех будет зависеть от способности государства, бизнеса и образовательных организаций совместно реализовать масштабную программу развития человеческого капитала, реформировать систему образования и сформировать культуру непрерывного обучения.

Список литературы

1. Отчет Всемирного экономического форума Future of Jobs Report, 2023. – URL: https://www3.weforum.org/docs/WEF_Future_of_Jobs_2023.pdf (дата обращения: 7.09.2026).
2. Главные навыки на рынке труда будущего: исследование MGI (Глобальный институт McKinsey). – URL: https://www.mckinsey.com/ru/our-insights/essential-skills-for-the-labor-market-of-the-future-mgi-research (дата обращения: 7.09.2026).

УДК 615.849

ПОЧЕМУ ИИ ОТЛИЧНО ПИШЕТ КОД, НО СПОТЫКАЕТСЯ НА ПРОСТОЙ МАТЕМАТИКЕ?

Тимохин Н.С., ORCID 0009-0007-1766-7097,
Филонова Е.С., ORCID 0009-0008-6809-9402
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
nazartimohin9@gmail.com, hiccup@mail.ru

Аннотация. В работе анализируются причины, по которым большие языковые модели LLM успешно генерируют программный код, но допускают ошибки при выполнении точных арифметических вычислений

Ключевые слова: большие языковые модели, LLM, арифметические вычисления в нейросетях.

Введение. В настоящее время нейросети всё чаще используют при программировании: они дописывают код, ищут в нём ошибки и создают небольшие программы по описанию на обычном языке. Но те же нейросети могут ошибиться в умножении многозначных чисел или в несложной школьной задаче. Это выглядит странно, ведь программирование считается более сложным делом, чем арифметика. Для понимания и решения проблемы рассмотрим, как устроены большие языковые модели (LLM), почему им проще «угадать» текст программы, чем посчитать результат, и как эту слабость можно обойти.

Цель работы – установить причины ошибок больших языковых моделей при выполнении точных арифметических вычислений, и определить практические способы повышения достоверности расчётов с использованием LLM.

Основная часть. LLM являются моделями типа «трансформер» [1]. Сначала текст делится на токены – небольшие кусочки: слова, части слов, знаки препинания. Самые распространённые токенизаторы работают по алгоритму BPE, который объединяет часто встречающиеся сочетания символов [2]. Модель учат одной простой задаче: по уже написанному тексту предсказывать следующий токен. Она просто продолжает текст так, как это обычно бывает в текстах из обучающей выборки.

С кодом такая схема работает хорошо по нескольким причинам. Во-первых, язык программирования строгий: правил синтаксиса немного, а типовые решения встречаются в обучающих данных очень часто. Модели остаётся продолжить знакомую конструкцию. Во-вторых, правильность кода часто можно проверить локально: если переменная объявлена выше, её можно использовать ниже, а открытую скобку нужно закрыть. В-третьих, ошибку в программе легко обнаружить: код не запустится или не пройдёт тест. Поэтому LLM уже применяют в средах разработки для автодополнения, поиска ошибок и рефакторинга [3].

Важно отличать знание алгоритма от умения его выполнить. Чтобы посчитать «в уме», нужно помнить промежуточные результаты и переносы и не ошибиться ни в одном шаге, а у модели нет другой памяти, кроме уже написанных токенов. Получается, что программа умножения для неё – просто текст, похожий на тысячи других, а умножение двух больших чисел – вычисление, для которого готового образца может не быть. Поэтому объяснить процедуру модели проще, чем получить по ней результат.

Есть и причина, связанная с данными для обучения. В интернете, книгах и репозиториях очень много готового кода, а подробных вычислений с длинными числами в текстах мало: обычно пишут только итоговый ответ. Поэтому образцов для арифметики модель видит меньше, чем для программирования, и хуже обобщает их на новые числа.

У арифметики есть ещё несколько сложностей. Первая связана с токенизацией. Число может разбиваться на токены неудачно, для решения проблемы сейчас числа разбивают на отдельные цифры. Вторая сложность в том, ошибка в одной цифре делает всё решение неверным, а неточную программу можно исправить после проверки. Третья – ограниченность вычислений: на каждый токен модель тратит фиксированный объём работы, а длинное умножение требует цепочки шагов с переносами. Наконец, нейросеть подбирает параметры по примерам, поэтому она хорошо находит закономерности, но строгого выполнения правил, как у калькулятора, не гарантирует [4]. Сравнение двух видов задач приведено в таблице.

Таблица

Сравнение написания кода и точной арифметики

Свойство	**Написание кода**	**Точная арифметика**
Похожие примеры в данных	Очень много	Мало для длинных чисел
Ошибка в одном токене	Обычно находят тесты	Ответ неверный
Влияние токенизации	Слабое	Сильное
Что делает модель	Пишет по образцу	Считает по шагам

Нужно сказать, что и в программировании модель может ошибаться. Причина та же: модель воспроизводит наиболее вероятную конструкцию. Разница в том, что код можно запустить и проверить, а число, полученное «на глаз», модель сама проверить не может. Поэтому уверенный тон ответа ещё не говорит о его правильности.

Убедиться в этом можно самому: достаточно попросить модель перемножить два шестизначных числа и сравнить ответ с результатом на калькуляторе. Может получиться, что ответ выглядит очень правдоподобно и даже начинается с верных цифр, но в конце содержит ошибку.

Можно возразить, что модель достаточно обучить на большом количестве примеров по арифметике. Отчасти это помогает, но модель всё

равно встретит такие длины и сочетания цифр, которых не видела при обучении. Калькулятор же работает по правилу и одинаково решает задачу для любых чисел, поэтому в этом вопросе он надёжнее.

Слабость модели в расчётах можно частично компенсировать. Первый способ – попросить её решать по шагам, но ошибка на любом шаге всё равно попадёт в ответ. Второй способ – дать модели инструмент: калькулятор или интерпретатор кода. Тогда она пишет программу для расчёта, а считает уже компьютер. Получается, что парадокс из названия работает на пользу: там, где модель плохо считает, она хорошо пишет код, который посчитает за неё.

В последние годы появились и модели, которые перед ответом долго «рассуждают» и поэтому считают заметно лучше. Однако они тоже могут ошибиться, а на такие рассуждения уходит больше времени и вычислительных ресурсов, так что внешние инструменты остаются более надёжным способом.

Следует учитывать, что в работе рассмотрены общие причины, а конкретное поведение зависит от модели и её версии: новые модели, как правило, ошибаются реже старых. Поэтому сделанные выводы носят общий характер, и на практике их стоит проверять на собственных примерах.

Заключение. Успехи LLM в программировании и ошибки в простой математике имеют одну причину: модель предсказывает правдоподобное продолжение текста, а не выполняет алгоритм. В коде много типовых конструкций, и его можно проверить автоматически, а точный расчёт требует строгих шагов, на которые не рассчитаны ни сама модель, ни токенизация чисел. Понимание того, как устроена LLM, помогает использовать её там, где она сильна, и не доверять ей слепо там, где нужна точность.

Список литературы

1. Аламмар, Д. Большие языковые модели на практике: понимание языка и генерация текстов / Д. Аламмар. – М. Гроотендорст; перевод с английского К. Назарова. – Астана: АЛИСТ, 2026. – 416 с. – ISBN 978-601-12-6517-1.
2. Языковые модели // Учебник по машинному обучению / Школа анализа данных Яндекса. – Текст: электронный. – URL: https://contest.yandex.ru/tracks/ml/generative-models/language-models (дата обращения: 29.09.2026).
3. Ишанхонов, А. Ю. Роль больших языковых моделей в интегрированных средах разработки нового поколения / А. Ю. Ишанхонов, Д. В. Пшиченко, Е. А. Можаровский и др. // Программные системы и вычислительные методы. – 2024. – № 4. – С. 140–150. – DOI 10.7256/2454-0714.2024.4.72022. – EDN KMTOBG.
4. Николенко, С. И. Глубокое обучение: погружение в мир нейронных сетей / С. И. Николенко, А. А. Кадурин, Е. О. Архангельская. – Санкт-Петербург: Питер, 2018. – 480 с. – ISBN 978-5-496-02536-2.

УДК 004.65

ВЛИЯНИЕ ГЛУБИНЫ ДЕКОМПОЗИЦИИ НА ОБЪЁМ ХРАНЕНИЯ РАЗРЕЖЕННЫХ ДАННЫХ В РЕЛЯЦИОННОЙ БАЗЕ ДАННЫХ

Трофимов В.В., канд. техн. наук, ORCID 0009-0008-9955-3102,
Домарев В.И., вед. инженер, ORCID 0009-0003-5989-2867
ФГБНУ «Республиканский академический научно-исследовательский и проектно-конструкторский институт горной геологии, геомеханики, геофизики и маркшейдерского дела», г. Донецк, РФ
victor.trofymov@ranimi.org, vladimir.domarev@bk.ru

Введение. При проектировании информационных систем, в которых набор характеристик объекта заранее не фиксирован, применяется атрибутивная модель хранения [1]: вместо отдельного столбца на каждую характеристику значения хранятся строками вида «объект-параметр-значение». Такая организация позволяет расширять набор параметров без изменения структуры базы данных, однако при едином текстовом столбце значения сведения о типе перестают быть доступными механизмам контроля базы данных [2]. Устранить этот недостаток позволяет типизированный вариант модели, в котором тип параметра сохраняется в каталоге, а значения размещаются в столбцах соответствующих типов.

Для типизированного варианта существуют два принципиально различных способа организации хранения. Первый размещает значения разных типов в отдельных таблицах – по одной на тип данных. Каждая такая таблица однородна и не содержит неопределённых значений. Второй размещает типизированные столбцы непосредственно в записи значения. Вследствие чего в каждой записи заполнен ровно один столбец, а остальные остаются неопределёнными.

Первый способ представляет собой продолжение декомпозиции сверх требуемой функциональными зависимостями [3] и приближается к неприводимым отношениям шестой нормальной формы [4]. Одним из распространённых доводов в его пользу служит полное устранение неопределённых значений из хранения, из чего можно сделать предположение о сокращении занимаемого объёма. Но это заключение не подтверждается экспериментально.

Методика и результаты. Сопоставлены пять способов организации хранения расширяемого набора параметров: широкая таблица с отдельным столбцом на каждый параметр; атрибутивная модель с единым текстовым столбцом значения; документное хранение в формате JSONB; раздельная типизированная схема с отдельной таблицей на каждый тип данных; плоская типизированная схема с типизированными столбцами в записи значения.

Все схемы наполнялись идентичными данными: 50 тыс. объектов, каталог из 24 параметров, заполнение 30 %, что соответствует примерно

360 тыс. значений. Индексы во всех схемах создавались до загрузки. Объём определялся функцией pg_total_relation_size после полной очистки таблиц, включающей перестроение индексов. Измерения выполнены в трёх независимых прогонах на PostgreSQL 18.3. В таблице приведены медианы.

Таблица

Объём хранения при 360 тыс. значений параметров

Схема хранения	Объём, МБ	Байт на значение	Доля пустых ячеек
Широкая таблица	7,4	22	около 70 %
Документное хранение	18,9	55	–
Атрибутивная (текстовая)	39,8	116	нет
Плоская типизированная	53,7	157	8 из 9 столбцов
Раздельная типизированная	74,7	218	нет

Схема, полностью исключающая неопределённые значения, оказалась наиболее затратной, а широкая таблица, в которой пустует около 70 % ячеек, – наиболее компактной. Различие достигает десяти раз. Порядок схем в таблице обратен степени устранения неопределённых значений.

Объяснение следует из внутреннего устройства хранилища [5]. Неопределённые значения учитываются битовой картой – по одному биту на столбец записи, то есть один-два байта на запись независимо от числа незаполненных столбцов. Каждая же дополнительная запись сопровождается заголовком в 24 байта, указателем в странице, значением внешнего ключа и записью в индексе первичного ключа. Разность объёмов раздельной и плоской схем составила 61 байт на значение, что соответствует именно накладным расходам на одну дополнительную запись, поскольку раздельная схема хранит каждое значение двумя записями в разных таблицах вместо одной.

Широкая таблица представляет предельный случай той же закономерности. Она распределяет накладные расходы одной записи сразу на 24 значения параметров, вследствие чего оказывается компактной несмотря на разреженное заполнение.

При уменьшении набора на порядок, до 36 тыс. значений, удельные объёмы составили 23, 121, 161 и 226 байт на значение для широкой, атрибутивной, плоской и раздельной схем соответственно, то есть сохранили прежний порядок и близкие величины.

Выводы. В реляционной базе данных с построчным хранением объём определяется в первую очередь числом записей, а не долей незаполненных ячеек: стоимость неопределённого значения составляет один бит, тогда как стоимость дополнительной записи – десятки байт.

При разреженных данных предпочтительны схемы с меньшим числом более широких записей. Продолжение декомпозиции сверх

требуемой функциональными зависимостями не даёт выигрыша в объёме, а при разнесении значения и его типизированного представления по разным таблицам увеличивает объём на 39 %.

Результат получен для PostgreSQL 18.3 и переносим на системы с построчным хранением и сопоставимой структурой записи. Для колоночных хранилищ, где неопределённые значения кодируются иначе, вывод требует отдельной проверки.

Информация о финансовой поддержке: *Исследование выполнено рамках государственного задания Министерства науки и высшего образования Российской Федерации (FRSR-2026-0006 «Исследование геодинамики глубинных разломов в геофизических полях структур Донбасса и прилегающих территорий»).*

Список литературы

1. Nadkarni, P. M. Organization of Heterogeneous Scientific Data Using the EAV/CR Representation / P. M. Nadkarni, L. Marenco, R. Chen [et al.] // Journal of the American Medical Informatics Association. – 1999. – Vol. 6, № 6. – P. 478–493.
2. Karwin, B. SQL Antipatterns: Avoiding the Pitfalls of Database Programming / B. Karwin // Pragmatic Bookshelf. – 2010. – 328 p.
3. Дейт, К. Дж. Введение в системы баз данных. 8-е изд. / К. Дж. Дейт. – М.: Вильямс. – 2005. – 1328 с.
4. Date, C. J. Temporal Data and the Relational Model / C. J. Date, H. Darwen, N. A. Lorentzos // Morgan Kaufmann. – 2003. – 422 p.
5. Рогов, Е. В. PostgreSQL изнутри / Е. В. Рогов. – М.: ДМК Пресс. – 2022. – 660 с.

УДК 004.451

ОБЗОР АЛГОРИТМОВ РАСЧЁТА ОБЪЁМОВ ОПЕРАТИВНОЙ ПАМЯТИ ПРИ ЕЁ ПЕРЕРАСПРЕДЕЛЕНИИ МЕЖДУ ВИРТУАЛЬНЫМИ МАШИНАМИ С УЧЁТОМ ОГРАНИЧЕНИЙ

Ферубко А.О., ORCID 0009-0006-5625-137X,
Казаков О.Д., канд. экон. наук, доц., ORCID 0000-0001-9665-8138
ФГБОУ ВО «Брянский государственный инженерно-технологический университет»,
г. Брянск, РФ
ferubko1999@yandex.ru, kazakov@bgitu.ru

Введение. Адаптивная система управления гипервизором KVM [1] прогнозирует потребление оперативной памяти (ОП) гостевой и хостовой операционных систем (ОС) линейной регрессией и при расхождении прогнозов свободной ОП больше окна ε перераспределяет ОП между виртуальными машинами (ВМ) без перезагрузки с помощью механизма balloon [2], выравнивая свободную ОП во всех подсистемах. Это правило не учитывает системный минимум ОС, объём ОП для запуска приложений,

гарантированный клиенту запас и предел разового изъятия ОП. Цель работы – обзор алгоритмов, способных заменить правило выравнивания с учётом этих ограничений.

Основная часть. Пусть в системе N подсистем (в [1] $N=2$), x_i^0 – текущий объём ОП i-й подсистемы, p_i – прогноз её потребления, $f_i = x_i^0 - p_i$ – прогноз свободной ОП, $M = x_1^0 + \cdots + x_N^0$ – общий объём ОП, который при перераспределении не меняется. Требуется найти новые объёмы x_i. Алгоритм из [1] вычисляет

$$x_i = p_i + \frac{1}{N}\left(M - \sum_{j=1}^{N} p_j\right) \tag{1}$$

и отменяет перераспределение, если хотя бы один x_i меньше системного минимума m_i, хотя допустимое решение может существовать. В общем виде ограничения записываются так:

$$\sum_{i=1}^{N} x_i = M, \quad l_i \le x_i \le u_i, \tag{2}$$

$$l_i = \max\left\{m_i + r_i,\ p_i + g_i,\ (1-\delta)x_i^0\right\}, \tag{3}$$

где r_i – резерв ОП для запуска типовых приложений, g_i – гарантированный клиенту запас свободной ОП, δ – предельная доля разового изъятия, u_i – максимальный объём ОП из конфигурации ВМ. Если $l_1 + \cdots + l_N > M$, часть ограничений переводят в штрафы.

1. **Весовое пропорциональное распределение.** Каждая ВМ получает нижнюю границу l_i, а остаток делится пропорционально весам w_i (по тарифу клиента); при $x_i > u_i$ объём фиксируют на u_i и пересчитывают остальные:

$$x_i = l_i + \frac{w_i}{\sum_{j=1}^{N} w_j}\left(M - \sum_{j=1}^{N} l_j\right). \tag{4}$$

2. **Ограниченное выравнивание (water-filling)** обобщает (1). При общем уровне свободной ОП λ

$$x_i(\lambda) = \min\left\{u_i,\ \max\left\{l_i,\ p_i + w_i\lambda\right\}\right\}. \tag{5}$$

Сумма $x_1(\lambda) + \cdots + x_N(\lambda)$ не убывает по λ, поэтому уровень, при котором она равна M, находят бисекцией. При $w_i = 1$ и без границ (5) совпадает с (1), а при $N=2$ результат (1) достаточно ограничить отрезком $\left[\max\{l_1, M-u_2\}, \min\{u_1, M-l_2\}\right]$.

3. **Линейное программирование (ЛП)** максимизирует наименьший взвешенный запас свободной ОП при ограничениях (2); в него легко добавить новые линейные условия.

4. **Квадратичное программирование (КП)** минимизирует взвешенную сумму квадратов отклонений:

$$\sum_{i=1}^{N}\left[\alpha_i(x_i-p_i-g_i)^2+\beta(x_i-x_i^0)^2\right]\to\min. \tag{6}$$

Первое слагаемое приближает свободную ОП к запасу g_i, второе штрафует перемещения ОП. Задача выпуклая, решается за $O(N\log N)$ [3].

5. **Теоретико-игровой подход.** Решение торга по Нэшу находят из условия

$$\sum_{i=1}^{N} w_i \ln(x_i-d_i)\to\max \tag{7}$$

при ограничениях (2), где $d_i=l_i$ – точка несогласия. Без верхних границ решение совпадает с (4), что обосновывает весовое распределение [4].

6. **Регуляторы с обратной связью** меняют объём малыми шагами по отклонению $e_i=g_i-f_i$. ПИД-регулятор вычисляет шаг

$$\Delta x_i(k)=K_P e_i(k)+K_I\sum_{s=0}^{k} e_i(s)+K_D\left(e_i(k)-e_i(k-1)\right), \tag{8}$$

с ограничением $|\Delta x_i|\le\delta x_i^0$, балансировкой $\Delta x_1+\dots+\Delta x_N=0$ и проекцией на $[l_i,u_i]$ [5].

7. **Метаэвристики и обучение с подкреплением** (NSGA-II, DQN, PPO) учитывают дефицит ОП, объём перемещений и нарушения ограничений [6], проецируя решения на (2), (3). Итоги – в таблице.

Таблица

Сравнение алгоритмов расчёта объёмов ОП

Алгоритм	Ограничения	Сложность	Пакеты Python 3
Выравнивание (1)	только проверка	$O(N)$	не требуются
Весовое (4)	да	$O(N^2)$	NumPy
Water-filling (5)	да	$O(N\log\frac{1}{\varepsilon})$	NumPy, SciPy
ЛП	да	полиномиальная	SciPy, PuLP, OR-Tools
КП (6)	да	$O(N\log N)$	CVXPY, OSQP
Нэш (7)	да	итеративная	CVXPY
ПИД (8)	проекция	$O(N)$	control, fuzzylogic
Метаэвристики, RL	проекция	высокая	pymoo, Stable-Baselines3

Заключение. Правило выравнивания из [1] – частный случай ограниченного выравнивания (5), которое при $N=2$ является лучшей заменой: оно соблюдает ограничения (2), (3) и сводится к явной формуле. Для сглаживания перераспределений целесообразно КП (6). Далее планируется экспериментально сравнить (5) и (6).

Список литературы

1. Ферубко, А. О. Сравнительное исследование методов линейной регрессии для построения адаптивной системы управления в высокопроизводительных средах виртуализации / А. О. Ферубко, О. Д. Казаков // Вестник Рязанского государственного радиотехнического университета. – 2026. – № 95. – С. 73–84. – DOI 10.21667/1995-4565-2026-95-73-84.

2. Lambert S. Consolidation of virtual machines to reduce energy consumption of data centers by using ballooning, sharing and swapping mechanisms / S. Lambert, E. Caron, L. Lefevre [et al.] // Future Generation Computer Systems. – 2026. – Vol. 174. – Art. 107968. – DOI 10.1016/j.future.2025.107968.
3. Schoot Uiterkamp, M. H. H. A fast algorithm for quadratic resource allocation problems with nested constraints / M. H. H. Schoot Uiterkamp, J. L. Hurink, M. E. T. Gerards // Computers & Operations Research. – 2021. – Vol. 135. – Art. 105451. – DOI 10.1016/j.cor.2021.105451.
4. Hassan, M. M. Virtual machine resource allocation for multimedia cloud: a Nash bargaining approach / M. M. Hassan, A. Alamri // Procedia Computer Science. – 2014. – Vol. 34. – P. 571–576. – DOI 10.1016/j.procs.2014.07.074.
5. Saikrishna, P. S. Multi-objective switching controller for cloud computing systems / P. S. Saikrishna, R. Pasumarthy // Control Engineering Practice. – 2016. – Vol. 57. – P. 72–83. – DOI 10.1016/j.conengprac.2016.09.001.
6. Chen, L. A deep reinforcement learning approach to cloud resource optimization with response time distributions / L. Chen, C. Jiang, Q. Zhong // Expert Systems with Applications. – 2026. – Vol. 296. – Art. 129081. – DOI 10.1016/j.eswa.2025.129081.

УДК 004.415.2:519.216

ПОРОГОВАЯ ЦВЕТОВАЯ ИНДИКАЦИЯ СОСТОЯНИЯ КОМПОНЕНТОВ: ГИСТЕРЕЗИС И ПОДАВЛЕНИЕ ДРЕБЕЗГА

Чекашов Д.Э., Юдина А.В., Гибадуллин Р.Ф., канд. техн. наук, доц.
ФГБОУ ВО «Казанский национальный исследовательский технический университет – Казанский авиационный институт им. А. Н. Туполева», г. Казань, РФ
d.chekashov@bk.ru, annyudina04@yandex.ru, RuslanGibadullin@vk.com

Введение. Цветовая индикация «норма – внимание – перегрев» – наиболее заметный элемент диагностического приложения: именно цвет, а не число, воспринимается пользователем как ответ на вопрос, всё ли в порядке с оборудованием. Формирующее его правило сводится к двум пороговым сравнениям и кажется тривиальным, пока контролируемая величина не оказывается вблизи порога. Показания датчиков зашумлены (разброс температуры порядка градуса), поэтому отсчёты попадают то выше, то ниже порога, и индикатор переключается почти при каждом опросе. Такой дребезг подрывает доверие к цвету и порождает поток ложных уведомлений. Задача устойчивого порогового решения при зашумлённых наблюдениях возникает и при выделении значимых областей изображений [1], а её вероятностная постановка близка к оценке вероятностных характеристик автоматизированных систем [2].

Цель работы – построить вероятностную модель частоты ложных переключений индикации, получить правило назначения ширины гистерезиса по допустимому числу переключений и сопоставить

гистерезис с альтернативными механизмами подавления дребезга по вносимому запаздыванию.

Основная часть. Пусть величина наблюдается с периодом T по модели $x_k = s_k + \xi_k$, $\xi_k \sim N(0, \sigma^2)$, где s_k изменяется медленно, а для датчиков температуры процессоров $\sigma \approx 1$–2 °C. Наихудший режим для классификатора – не быстрый рост температуры, а длительное пребывание вблизи порога при умеренной нагрузке. Введём гистерезис: переход вверх происходит при достижении порога θ, возврат – при снижении ниже $\theta - h$. Классификатор описывается цепью Маркова с двумя состояниями; при среднем значении m вероятности переходов на одном отсчёте и стационарная частота смены состояния равны

$$a = Q((\theta - m)/\sigma), \quad b = Q((m - \theta + h)/\sigma), \quad \nu = 2ab/(a + b), \tag{1}$$

где $Q(\cdot)$ – дополнительная функция стандартного нормального распределения. В наихудшем случае $m = \theta$ ($a = 1/2$) при $h \geq 2\sigma$ получаем $\nu \approx 2Q(h/\sigma)$, а число переключений в час $N = 3600\nu / T$. Обращение даёт правило назначения ширины гистерезиса по допустимому числу переключений:

$$h = \sigma Q^{-1}(\nu_{\text{доп}}/2), \quad \nu_{\text{доп}} = N_{\text{доп}} T / 3600. \tag{2}$$

Результаты для $T = 1$ с и $\sigma = 0{,}75$ °C (сглаженные показания) приведены в таблице 1.

Таблица 1

Частота ложных переключений в зависимости от ширины гистерезиса

h / σ	**0**	**1**	**2**	**3**	**4**	**5**
Переключений в час	1800	867	157	9,7	0,23	0,002
h, °C	0	0,75	1,5	2,25	3,0	3,75

Каждое дополнительное σ ширины снижает частоту переключений более чем на порядок, поэтому гистерезис «с запасом» обходится дёшево. Для требования «не более одного ложного переключения в час» из (2) следует $h = 3{,}63\sigma = 2{,}7$ °C, что много меньше расстояния 15 °C между порогами 75 и 90 °C, так что зоны уровней не перекрываются.

Гистерезис применяется асимметрично: переход вверх выполняется сразу по достижении порога, а возврат требует снижения на h, поскольку запоздалое предупреждение о перегреве опасно, а запоздалое снятие – безобидно. Реализация сводится к конечному автомату с тремя состояниями. Запаздывание обнаружения при этом не растёт, а задержка снятия при скорости остывания $v_{\text{ост}}$ составляет

$$\Delta_{\text{сн}} = T + h / v_{\text{ост}} \approx 2{,}4 \text{ с} \quad \text{при} \quad v_{\text{ост}} = 2 \text{ °C/с}. \tag{3}$$

Альтернатива – подтверждение решения серией из k отсчётов – даёт частоту ложных подтверждений порядка $(1/2)^k$ при запаздывании обнаружения kT; эквивалентное подавление требует $k = 12$ (таблица 2).

Подавление у обоих механизмов одинаково, но серия отсчётов платит запаздыванием обнаружения – тем свойством, ради которого индика-

ция существует, а гистерезис – задержкой снятия, не имеющей практических последствий. Дополнительное минимальное время удержания цвета (около 5 с) устраняет мерцание, воспринимаемое зрительно.

Таблица 2

Сопоставление механизмов подавления дребезга

Механизм	**Переключений в час**	**Задержка обнаружения**	**Задержка снятия**
Без мер	1800	1 с	1 с
Подтверждение серией, k = 12	0,9	12 с	12 с
Гистерезис, h = 2,7 °C	1,0	1 с	2,4 с

Ширина гистерезиса пропорциональна σ, поэтому её уменьшает сглаживание. Для экспоненциального фильтра $y_k = \alpha x_k + (1 - \alpha) y_{k-1}$ с коэффициентом α и выброса длительностью τ и амплитудой A

$$\sigma_y = \sigma\sqrt{(\alpha / (2 - \alpha))}, \quad A_{вых} = A[1 - (1 - \alpha)^{\tau/T}]. \qquad (4)$$

При $\alpha = 0{,}4$ шум снижается вдвое, но односекундный выброс на 10 °C проходит на выход как 4 °C и при запасе до порога 5 °C остаётся незамеченным. Для индикации это приемлемо, но недопустимо для критических уведомлений. Поэтому пути обработки разделяются: индикация формируется по сглаженному значению с гистерезисом, а уведомление – по исходному, с коротким подтверждением против единичных сбойных отсчётов. При агрегировании M датчиков в одну карточку требуемая ширина $h_M = \sigma Q^{-1}(v_{доп} / (2M))$ при $M = 3$ растёт лишь на 8 % (до $3{,}91\sigma$). Ширина гистерезиса не задаётся числом, а вычисляется по (2) из указанных в профиле устройства шума и допустимого числа переключений, что исключает рассогласование параметров [4]; число переключений на записанных показаниях проверяется в регрессионных испытаниях [3]. Модель предполагает нормальный некоррелированный шум, поэтому для реальных данных даёт оценку порядка величины; значение σ следует измерять для каждой модели оборудования в установившемся тепловом режиме.

Заключение. Построена марковская модель дребезга пороговой цветовой индикации и получено правило назначения ширины гистерезиса по допустимому числу ложных переключений в час. Гистерезис шириной $3{,}63\sigma$ снижает число переключений у порога с 1800 до одного в час, а при асимметричном применении не увеличивает запаздывания обнаружения перегрева; эквивалентное подтверждение серией требует 12 отсчётов и задерживает обнаружение на 12 периодов. Показано, что сглаживание ослабляет короткие выбросы, что требует раздельных путей формирования индикации и критического уведомления.

Информация о финансовой поддержке: *Научные результаты, изложенные в данной статье, были получены в рамках реализации программы стратегического академического лидерства «Приоритет-2030» (соглашение № 075-15-2026-055 от «06» апреля 2026 г.).*

Список литературы

1. Метод выделения значимых областей в графической информации для систем поддержки принятия решений / И. Р. Сайфудинов, В. В. Мокшин, А. П. Кирпичников [и др.] // Вестник Технологического университета. – 2018. – Т. 21, № 6. – С. 146–152. – EDN XUALUT.
2. Моисеев, В. С. К задаче определения вероятностных характеристик информационной безопасности разрабатываемых автоматизированных систем управления / В. С. Моисеев, П. И. Тутубалин. – 2007. – Деп. в ВИНИТИ 11.01.2007, № 26-В2007. – EDN PKCNAT.
3. Рахманов, А. С. Автоматизация тестирования безопасности веб-приложений / А. С. Рахманов, П. И. Тутубалин // Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований: материалы IV Всерос. нац. науч. конф. – Комсомольск-на-Амуре: КнАГУ, 2021. – Ч. 3. – С. 298–301. – EDN MHNKNA.
4. Raikhlin, V. The Influence of the Form of Digital Etalons on the Effectiveness of Associative Security / V. Raikhlin, R. Gibadullin, A. Boyko // Computers. – 2026. – Vol. 15, No. 3. – P. 167. – DOI 10.3390/computers15030167.

УДК 004.932

ПОВЫШЕНИЕ РАЗРЕШЕНИЯ ЦИФРОВЫХ ИЗОБРАЖЕНИЙ: МЕТОДЫ, ОГРАНИЧЕНИЯ, ПЕРСПЕКТИВЫ

***Чернядьев И.В.*[1,2],** ORCID 0009-0008-6557-1601,
***Ермоленко Т.В.*[1],** канд. техн. наук, доц., ORCID 0000-0001-5701-1956
[1]ФГБНУ «Институт прикладной математики и механики», г. Донецк, РФ
[2]ФГБНУ «Институт проблем искусственного интеллекта», г. Донецк, РФ
chernyadev-i@mail.ru, naturewild71@yandex.ru

Введение. Изображения в медиа, системах видеонаблюдения и дистанционного зондирования часто теряют детали из-за сжатия, масштабирования и фильтрации. Задача повышения разрешения (super-resolution, SR) состоит в восстановлении изображения высокого разрешения по его низкоразрешённой версии. Интерполяция не восстанавливает высокочастотные детали, поэтому основным подходом стали методы глубокого обучения.

Цель работы – сравнительный анализ архитектур глубокого обучения для повышения разрешения изображений с учётом противоречия между пиксельными и перцептивными метриками качества и выявление перспективных направлений их развития.

Основная часть. *Метрики качества.* Методы SR традиционно оценивают по PSNR и SSIM [1]. PSNR вычисляется через среднеквадратическую ошибку, которая одинаково штрафует любые отклонения независимо от их пространственной структуры: изображение

со сдвинутым на один пиксель объектом имеет меньший PSNR, чем слегка размытое, хотя первое визуально почти неотличимо от оригинала. SSIM учитывает структуру и контраст, но также слабо отражает качество текстур. Минимизация пиксельной ошибки даёт высокий PSNR, но сглаженные изображения. Перцептивные функции потерь [2] и состязательное обучение (GAN) [3, 4] позволяют получить реалистичные текстуры ценой снижения PSNR; для оценки таких результатов применяют метрику LPIPS [5], основанную на расстоянии между признаками глубокой сети. В работе [6] показано, что искажение и воспринимаемое качество принципиально не могут быть оптимизированы одновременно, поэтому прямое сопоставление PSNR моделей двух типов некорректно.

В таблице приведены результаты методов обеих групп на тестовом наборе Set5 при четырёхкратном увеличении.

Таблица

Результаты методов повышения разрешения на наборе Set5 (×4)

Метод	**Год**	**Архитектура**	**Функция потерь**	**PSNR, дБ**	**SSIM**	**LPIPS**
Бикубическая интерполяция	–	–	–	28,42	0,8245	0,341
SRCNN [7]	2016	CNN	L2	30,48	0,8628	–
RCAN [8]	2018	CNN	L1	32,63	0,9002	–
SwinIR [9]	2021	Трансформер	L1	32,92	0,9044	–
HAT [10]	2023	Трансформер	L1	33,04	0,9056	–
SRGAN [3]	2017	CNN	перцепт. + GAN	29,17	0,8613	0,088
ESRGAN [4]	2018	CNN	перцепт. + GAN	30,45	0,8677	0,075
SPSR [11]	2020	CNN	перцепт. + GAN	30,40	0,8627	0,064

Примечание. PSNR и SSIM методов с пиксельной функцией потерь – по данным исходных работ; значения для бикубической интерполяции и GAN-методов – по [11]; «–» – значение LPIPS в исходной работе не приводится.

Из таблицы следуют два вывода. Во-первых, рост PSNR у моделей с пиксельной функцией потерь замедляется: переход от SRCNN к RCAN дал 2,15 дБ, от RCAN к SwinIR – 0,29 дБ, от SwinIR к HAT – 0,12 дБ, при этом HAT содержит 20,8 млн параметров против 11,9 млн у SwinIR [10]. Во-вторых, GAN-методы уступают лучшим моделям около 2,5 дБ по PSNR, но снижают LPIPS в 4–5 раз по сравнению с бикубической интерполяцией, что согласуется с выводом [6].

Диффузионные модели. Диффузионные модели, начиная с SR3 [12], формируют изображение итеративным шумоподавлением и дают наиболее реалистичные текстуры. Их оценивают на других наборах данных, поэтому в табл. 1 они не включены. Их недостаток – вычислительная стоимость: модели SR3 содержат 550–625 млн параметров и многократно прогоняют сеть. Метод ResShift [13] сокращает число шагов до 15, OSEDiff [14] – до одного.

Отдельная проблема – реальные искажения: методы табл. 1 обучены на бикубически уменьшенных изображениях и хуже работают на снимках

с шумом и артефактами сжатия; для её решения предложено обучение со случайной моделью деградации [15].

Перспективными направлениями представляются:

1) учёт физической модели формирования изображения (функции рассеяния точки, шума сенсора) – важен для спутниковой съёмки и медицины, где генеративные модели могут добавить несуществующие детали;

2) использование дополнительных модальностей (карты глубины, инфракрасные каналы, данные лидаров);

3) снижение вычислительной стоимости: квантизация (INT8), бинаризация, сокращение числа шагов диффузии.

Заключение. Выбор архитектуры определяется требованиями задачи. Если важна достоверность, следует использовать модели с пиксельной функцией потерь, среди которых лучший PSNR у трансформеров (SwinIR, HAT), хотя прирост качества при росте размера моделей уменьшается. Если важна визуальная реалистичность, предпочтительны GAN и диффузионные модели, качество которых следует оценивать перцептивными метриками, а не PSNR.

Информация о финансовой поддержке*: Исследование выполнено при финансовой поддержке Минобрнауки России (регистрационный номер 1023111000141-9-1.2.1).*

Список литературы

1. Wang Z. Image quality assessment: from error visibility to structural similarity / Z. Wang, A. C. Bovik, H. R. Sheikh [et al.] // IEEE Transactions on Image Processing. – 2004. – Vol. 13, № 4. – P. 600–612.
2. Johnson J. Perceptual losses for real-time style transfer and super-resolution / J. Johnson, A. Alahi, L. Fei-Fei // Computer Vision – ECCV 2016. – Springer, 2016. – P. 694–711.
3. Ledig C. Photo-realistic single image super-resolution using a generative adversarial network / C. Ledig, L. Theis, F. Huszár [et al.] // Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). – 2017. – P. 4681–4690.
4. Wang X. ESRGAN: Enhanced super-resolution generative adversarial networks / X. Wang, K. Yu, S. Wu [et al.] // Computer Vision – ECCV 2018 Workshops. – Springer, 2019. – P. 63–79.
5. Zhang R. The unreasonable effectiveness of deep features as a perceptual metric / R. Zhang, P. Isola, A.A. Efros [et al.] // Proc. CVPR. – 2018. – P. 586–595.
6. Blau Y. The perception-distortion tradeoff / Y. Blau, T. Michaeli // Proc. CVPR. – 2018. – P. 6228–6237.
7. Dong C. Image super-resolution using deep convolutional networks / C. Dong, C.C. Loy, K. He [et al.] // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2016. – Vol. 38, № 2. – P. 295–307.
8. Zhang Y. Image super-resolution using very deep residual channel attention networks / Y. Zhang, K. Li, K. Li [et al.] // Computer Vision – ECCV 2018. – Springer, 2018. – P. 286–301.
9. Liang J. SwinIR: Image restoration using Swin Transformer / J. Liang, J. Cao, G. Sun [et al.] // Proc. IEEE/CVF Int. Conf. on Computer Vision Workshops (ICCVW). – 2021. – P. 1833–1844.

10. Chen X. Activating more pixels in image super-resolution transformer / X. Chen, X. Wang, J. Zhou [et al.] // Proc. CVPR. – 2023. – P. 22367–22377.
11. Ma C. Structure-preserving super resolution with gradient guidance / C. Ma, Y. Rao, Y. Cheng [et al.] // Proc. CVPR. – 2020. – P. 7769–7778.
12. Saharia C. Image super-resolution via iterative refinement / C. Saharia, J. Ho, W. Chan [et al.] // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2023. – Vol. 45, № 4. – P. 4713–4726.
13. Yue Z. ResShift: Efficient diffusion model for image super-resolution by residual shifting / Z. Yue, J. Wang, C.C. Loy // Advances in Neural Information Processing Systems. – 2023. – Vol. 36.
14. Wu R. One-step effective diffusion network for real-world image super-resolution / R. Wu, L. Sun, Z. Ma [et al.] // Advances in Neural Information Processing Systems. – 2024. – Vol. 37.
15. Zhang K. Designing a practical degradation model for deep blind image super-resolution / K. Zhang, J. Liang, L. Van Gool [et al.] // Proc. IEEE/CVF Int. Conf. on Computer Vision (ICCV). – 2021. – P. 4791–4800.

УДК 004.8:004.052

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ КОМПЬЮТЕРНЫХ СИСТЕМ

Шкуркин Д.В., доц., ORCID 0000-0002-2390-9300
ООО «Комплексные адаптивные системы», г. Таганрог, РФ
Политехнический институт (филиал) ФГБОУ ВО «Донской государственный технический университет» в г. Таганроге, г. Таганрог, РФ
dmitry.shkurkin@gmail.com

Введение. Прогнозирование отказов предполагает оценку будущего состояния узла, а не распознавание уже наступившей неисправности. Поэтому различение диагностических и прогностических признаков принципиально для корректности исследования. Наблюдения за дисковыми накопителями показывают, что корреляция отдельных показателей S.M.A.R.T. с отказами не гарантирует надежного индивидуального прогноза [1].

Цель. Разработать и проверить воспроизводимый протокол сравнения классификаторов при редком положительном классе как основу последующей апробации прогнозирования отказов. Сопоставляются метрики классификации и ранжирования. Работа имеет методический характер: численная проверка выполнена на синтетических, а не на эксплуатационных данных.

Основная часть. Для узла i в момент t целевой признак $y_i(t)$ равен единице, если отказ происходит в интервале (t; t + h], где h – горизонт предупреждения. Признаки $x_i(t)$ должны формироваться только из

наблюдений, доступных к моменту t. Предлагается оценивать риск и принимать решение по правилу:

$$\hat{p}_i(t) = f\theta(x_i(t)), \quad \hat{y}_i(t) = 1\{\hat{p}_i(t) \geq \tau\},$$

где fθ – обученная модель, τ – порог предупреждения. В настоящем эксперименте временная структура и физическая деградация не моделируются; проверяется только классификационный компонент указанной постановки.

Средствами scikit-learn [2] сформированы 12 000 наблюдений с десятью числовыми признаками: шесть информативных, два избыточных и два шумовых. Генератор make_classification использует два кластера на класс, исходные веса классов 0,9 и 0,1, параметр случайного изменения меток 0,01 и random_state = 2026. Фактическая доля положительного класса составила 10,39 %. Признакам не приписывались физические единицы или названия датчиков.

Стратифицированное разбиение выполнено в пропорции 60/20/20: 7200 объектов для обучения и по 2400 для валидации и тестирования. Сравнивались логистическая регрессия (LR; C = 1), случайный лес (RF; 300 деревьев, глубина до 10, минимум 5 объектов в листе) и гистограммный градиентный бустинг (GB; 200 итераций, шаг 0,05, до 15 листьев). Стандартизация для LR оценивалась только по обучающей части. Для каждой модели порог выбирался по максимуму F1 на валидации из сетки 0,01–0,99 с шагом 0,01; тестовые данные при выборе не использовались.

Основной показатель ранжирования – average precision (AP), суммирующий точность с весами приращений полноты. Дополнительно рассчитаны Precision, Recall, F1 и ROC-AUC. Для несбалансированных классов анализ Precision–Recall позволяет непосредственно оценить компромисс между обнаружением положительных случаев и ложными предупреждениями [3]. В тестовой части 250 положительных объектов; доля класса составляет 0,104, а Accuracy постоянного отрицательного ответа – 0,896.

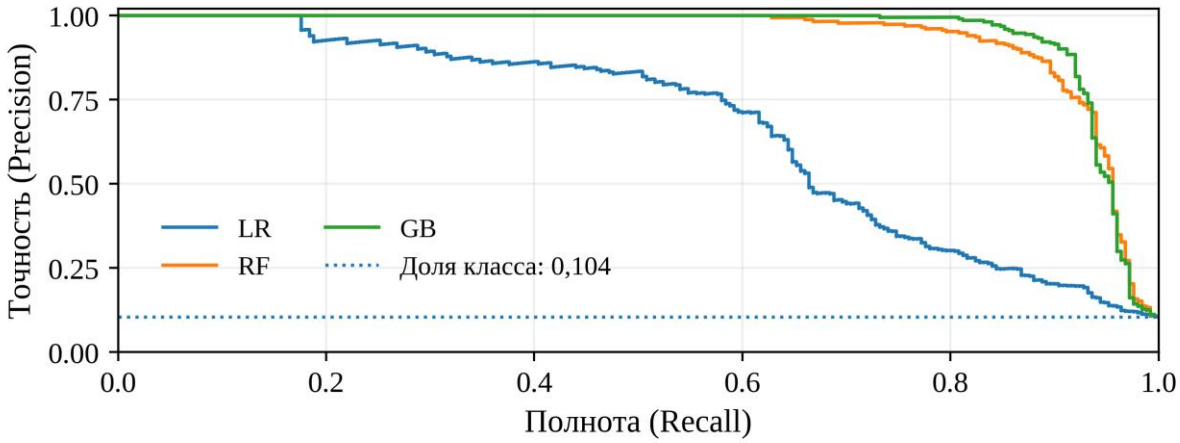


Рис. Кривые Precision–Recall на синтетической тестовой выборке

Таблица

Тестовые показатели при порогах, выбранных на валидации

Модель	Порог τ	Precision	Recall	F1	AP
LR	0,330	0,703	0,616	0,657	0,674
RF	0,260	0,887	0,876	0,881	0,937
GB	0,320	0,948	0,872	0,908	0,946

GB выбран по валидационной F1; на тесте он обеспечил F1 = 0,908 и AP = 0,946. При τ = 0,32 выявлены 218 из 250 положительных случаев, сформированы 12 ложных предупреждений и пропущены 32 случая. RF обнаружил на один положительный случай больше, но дал 28 ложных предупреждений. Следовательно, предпочтение GB в этом опыте связано прежде всего с уменьшением ложных тревог, а не с максимальной полнотой обнаружения.

Неопределенность AP оценена стратифицированным процентильным bootstrap: 1000 повторных выборок из теста с сохранением численности классов. Условные 95%-е интервалы составили 0,620–0,728 для LR, 0,912–0,960 для RF и 0,920–0,968 для GB. Оценки относятся к уже обученным моделям и не учитывают вариацию обучения при других разбиениях. Близкие значения AP двух ансамблей не дают основания утверждать универсальное превосходство бустинга.

Высокое качество ансамблей характеризует структуру выбранного генератора. Оно не подтверждает способность прогнозировать реальные отказы за заданное время. Независимые синтетические строки не воспроизводят зависимость измерений одного устройства, различия моделей оборудования, пропуски телеметрии и изменение нагрузки. Кроме того, оценка AP зависит от распространенности положительного класса: при иной частоте отказов значения Precision могут существенно измениться.

Для эксплуатационной проверки предлагается разделять наблюдения по времени и устройствам, исключать признаки, возникающие после отказа, и учитывать цензурирование. Помимо качества классификации следует измерять фактическое время предупреждения, долю обнаруженных отказов и число ложных тревог на 1000 узло-дней. Порог необходимо выбирать с учетом стоимости профилактики и пропуска отказа; максимизация F1 сама по себе не определяет экономически оправданную стратегию обслуживания.

Заключение. Получен воспроизводимый протокол, разделяющий обучение, выбор порога и итоговое тестирование. Синтетический эксперимент показал, что высокая Accuracy без анализа редкого класса недостаточна для выбора классификатора. Практический результат работы – процедура оценки, а не подтвержденная система прогнозирования отказов. Ее проверка на временной истории реального оборудования является необходимым следующим этапом.

Список литературы

1. Pinheiro, E. Failure Trends in a Large Disk Drive Population / E. Pinheiro, W. D. Weber, L. A. Barroso. – Текст: электронный // 5th USENIX Conference on File and Storage Technologies. – 2007. – URL: https://www.usenix.org/conference/fast-07/failure-trends-large-disk-drive-population (дата обращения: 28.09.2026).
2. Pedregosa, F. Scikit-learn: Machine Learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort [et al.]. – Текст: непосредственный // Journal of Machine Learning Research. – 2011. – Vol. 12. – P. 2825–2830.
3. Saito, T. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets / T. Saito, M. Rehmsmeier. – DOI 10.1371/journal.pone.0118432. – Текст: непосредственный // PLoS ONE. – 2015. – Vol. 10, no. 3. – Art. e0118432.

УДК 658.562:629.7

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И ТЕХНОЛОГИЙ АНАЛИЗА ДАННЫХ ДЛЯ КОНТРОЛЯ КАЧЕСТВА АВИАЦИОННОЙ ПРОДУКЦИИ

Шумская В.В., ORCID 0009-0004-3076-4543,
Сенюшкин Н.С., доц.
ФГБОУ ВО «Уфимский университет науки и технологий», г. Уфа, РФ
vshumsv@gmail.com, kafedraatt@uust.ru

Авиационная промышленность относится к отраслям с предельно высокими требованиями к качеству: отказ даже одной детали может привести к тяжёлым последствиям, поэтому лопатки двигателей, элементы конструкции и партии сырья проходят многоступенчатую проверку. Растут объёмы выпуска, внедряются аддитивные технологии с присущими им дефектами, и контроль, основанный на опыте специалиста, всё чаще становится узким местом производства. Цель статьи – показать, как методы искусственного интеллекта (ИИ) и анализа данных применяются для контроля качества авиационной продукции в России и какие условия нужны для их встраивания в систему менеджмента качества (СМК).

Стандарт ГОСТ Р ИСО 9001–2015 опирается на процессный подход и принятие решений на основе объективных данных, а также предусматривает мониторинг, измерение, анализ и оценку результатов и управление несоответствующей продукцией [1]. Следовательно, полнота данных о состоянии продукции напрямую определяет эффективность управления качеством. Ручной визуальный контроль в этом отношении ограничен: результат осмотра зависит от человеческого фактора, а при росте выпуска контроль замедляет производство [2].

Основу автоматизированного визуального контроля составляет машинное зрение: камеры получают изображения детали, а алгоритмы, чаще всего свёрточные нейронные сети, обнаруживают дефекты,

определяют их размеры и класс. Показательна разработка Московского авиационного института: по сообщению издания, программное обеспечение выявляет дефекты и поры в металлических деталях по снимкам компьютерной томографии; использовались R-CNN и ImageNet, обучение проводилось на тысячах изображений изделий, напечатанных на 3D-принтере; проверка, по данным публикации, может быть ускорена в 1,5–3 раза, на момент публикации продукт тестировался [3]. Пример показывает роль обучающей выборки: данные становятся самостоятельным производственным ресурсом.

Анализ накопленных данных расширяет возможности ИИ-контроля. В системе контроля лопаток на «ОДК-Сатурн» результаты автоматически сохраняются для анализа дефектов [2]; при люминесцентном контроле формируется «цифровой след» продукции, позволяющий вести ретроспективную аналитику процесса [4]. Объединение результатов контроля с производственной информацией позволяет выявлять повторяющиеся дефекты, анализировать причины и корректировать технологию, смещая акцент с проверки отдельной детали на управление процессом, что согласуется с [1].

В России подобные решения уже используются. На «ОДК-Сатурн» внедрён автоматизированный люминесцентный контроль деталей авиадвигателей: система снимает все поверхности, находит и классифицирует дефекты, рассчитывает их геометрию и определяет годность в соответствии с нормативной документацией [4]. Там же эксплуатируется система «Точка контроля»: робот подаёт лопатку в зону осмотра, камеры сверхвысокого разрешения фиксируют поверхность, а нейросети выявляют отклонения от 40 мкм; решение применяется для деталей двигателей, включая ПД-8, и шести типов полированных лопаток компрессоров [2]. На входном контроле «РТ-Техприемка» планирует внедрить комплекс на основе ИИ для контроля стали, поставляемой предприятиям авиационного кластера Ростеха; заявлено выявление дефектов размером 300 мкм [5]. Примеры обобщены в таблице.

Таблица

Примеры применения ИИ и машинного зрения в контроле качества авиационной продукции (составлено авторами по данным [2–5])

№	Проект (объект контроля)	Технологии	Заявленный эффект
1	«ОДК-Сатурн», «Точка контроля»: лопатки, детали двигателей [2]	Робот, камеры высокого разрешения, нейросети	Отклонения от 40 мкм, сохранение результатов
2	«ОДК-Сатурн», люминес-центный контроль [4]	Машинное зрение, нейросети	Определение годности, «цифровой след»
3	«РТ-Техприемка» (планируется): сталь [5]	ИИ, нейросети, компьютерное зрение	Недопущение отгрузки дефектного сырья
4	МАИ (тестирование): детали, в т.ч. аддитивные [3]	R-CNN, ImageNet	Поиск дефектов и пор на снимках КТ, ускорение в 1,5–3 раза

Для встраивания ИИ-контроля в СМК предлагается последовательность шагов, представленная на рисунке. Критерии приёмки остаются заданными нормативной документацией; после сбора и разметки изображений модель проходит валидацию на контрольных образцах и некоторое время эксплуатируется параллельно с ручным контролем. Только затем алгоритм включают в документированную информацию СМК, закрепляя порядок применения, ответственность и правила прослеживаемости результатов. Контур замыкает мониторинг точности и переобучение модели при изменении условий производства.



Рис. Схема внедрения ИИ-контроля в СМК (составлено авторами на основе [1; 2; 4])

Можно выделить ряд проблем практического внедрения. Первая связана с данными: для обучения нужны представительные размеченные выборки, а редкие, но критичные дефекты в них представлены слабо. Вторая – интеграция в СМК: алгоритм контроля должен быть описан в документированной информации организации, а его результаты – прослеживаемыми и проверяемыми, как результаты других процедур контроля. Третья – квалификация персонала: специалисты должны уметь интерпретировать результаты алгоритмов и вовремя замечать снижение точности модели при смене сырья, оснастки или условий освещения.

Таким образом, ИИ и накопление цифровых данных расширяют возможности контроля качества авиационной продукции: контроль становится не только средством выявления несоответствий, но и источником информации для совершенствования производственного процесса. Для масштабирования опыта необходимы представительные данные, валидация и прослеживаемость алгоритмов в СМК и подготовка персонала.

Список литературы

1. ГОСТ Р ИСО 9001–2015. Национальный стандарт Российской Федерации. Системы менеджмента качества. Требования. – Москва: Стандартинформ, 2015.
2. В ОДК начали ИИ-контроль лопаток двигателей. – Текст : электронный // Rambler/Финансы: сайт. – 2026. – 11 июня. – URL: https://finance.rambler.ru/business/56583131-v-odk-nachali-ii-kontrol-lopatok-dvigateley/ (дата обращения: 02.10.2026).
3. Нейросеть на страже качества полётов: российские учёные разработали программное обеспечение для проверки авиадеталей. – Текст: электронный // Техинсайдер: сайт. – URL: https://www.techinsider.ru/technologies/1605577-neiroset-na-straje-kachestva-poletov-rossiiskie-uchenye-razrabotali-programmnoe-obespechenie-dlya-proverki-aviadetalei/ (дата обращения: 02.10.2026).

4. «Ростех» начал оценивать качество деталей авиадвигателей с помощью нейросетей. – Текст: электронный // ComNews: сайт. – 2023. – 7 апр. – URL: https://www.comnews.ru/digital-economy/content/225274/2023-04-07/2023-w14/rostekh-nachal-ocenivat-kachestvo-detaley-aviadvigateley-pomoschyu-neyrosetey (дата обращения: 02.10.2026).
5. «Ростех» будет контролировать качество стали для авиации с помощью искусственного интеллекта. – Текст: электронный // ZOOM.CNews: сайт. – URL: https://zoom.cnews.ru/news/item/511369 (дата обращения: 02.10.2026).

УДК 69:004.9

РАЗРАБОТКА МЕТОДА РАННЕЙ ОЦЕНКИ РИСКА НАРУШЕНИЯ СРОКОВ В ИНФОРМАЦИОННОЙ СИСТЕМЕ СТРОИТЕЛЬНОГО ПРОИЗВОДСТВА

Яковлев К.Я., ORCID 0009-0000-6730-0268,
Камальдинова З.Ф., канд. техн. наук, доц., ORCID 0000-0002-9999-5436
ФГБОУ ВО «Самарский государственный технический университет», г. Самара, РФ
godmorn@mail.ru, kamal_zzz@mail.ru

Введение. Сведения об одной строительной работе часто хранятся в календарном графике, общем журнале, актах, реестре замечаний и исполнительной документации. Файлы Word, Excel и PDF обновляются раздельно, поэтому причину отставания приходится устанавливать вручную. СП 48.13330.2019 определяет состав организационно-технологической и исполнительной документации [1], ISO 19650-1:2018 – принципы организации и версионирования информации [2]. Цель работы – разработать метод ранней оценки риска на данных единой информационной системы строительного производства.

Методы освоенного объёма и освоенного графика прогнозируют продолжительность проекта, однако результат зависит от сетевой модели и исходных данных [3, 4]. На срок влияет и готовность предстоящих работ [5]. Особенность предлагаемого метода состоит в совместном учёте ожидаемой даты завершения, временного резерва, готовности к началу, приёмки и качества записей. Вместе с оценкой выводятся её причины.

Информационная система. Программа проектируется как веб-приложение для участников строительного проекта. Центральный объект данных – работа. С её карточкой связаны план, суточное выполнение, приёмка, замечания и версии документов. Для исполнительной документации сохраняются участок, автор, дата и редакция. Сервер на Java и Spring Boot выполняет проверки и расчёты, PostgreSQL хранит историю, клиент на React и TypeScript предоставляет ролевой доступ.

PDF-документ ООС хранится по версиям. По запросу «разработка на ПК 43» программа предлагает фрагмент ведомости и диапазон пикетов; связь с работой подтверждает ПТО.

ПТО создаёт работу по плану и документации, производитель работ вносит суточный объём, технический надзор фиксирует приёмку и замечания. Руководитель видит отклонения и причины предупреждений. Все действия относятся к одной карточке, отдельный отчёт для расчёта не требуется.

Разрабатываемый метод. Сетевой план задаётся графом $G = (V, E)$, где G – граф проекта, V – множество работ, E – множество зависимостей «окончание – начало», а i – номер анализируемой работы. На дату контроля t_0 программа получает плановый объём V^p_i, фактический объём V^f_i и вычисляет остаток $V^r_i = V^p_i - V^f_i$. При среднем суточном темпе $\bar{v}_i$ прогноз определяется формулой:

$$\hat{T}_i = t_0 + \frac{V_i^r}{\bar{v}_i}.$$

В формуле $\hat{T}_i$ – прогнозируемая дата завершения работы i; t_0 – дата расчёта; V^r_i – оставшийся объём; $\bar{v}_i$ – среднее приращение за последние n рабочих дней. Подтверждённый нулевой объём учитывается, пропущенная запись исключается. Значение n задаётся для проекта. При нулевом темпе дата не вычисляется. Сроки связанных работ рассчитываются с учётом их последовательности и временного резерва.

Оценка готовности. Для работы i задаётся набор $C_i = \{c_1, \ldots, c_m\}$, где C_i – перечень условий начала работы, m – их количество, j – номер условия. Переменная c_j равна 1 для выполненного условия и 0 для невыполненного, а q_j задаёт его значимость. Коэффициент готовности рассчитывается как:

$$K_i^g = \frac{\Sigma_j q_j c_j}{\Sigma_j q_j}, \quad 0 \le K_i^g \le 1.$$

Коэффициент K^g_i от 0 до 1 показывает готовность работы i. Неизвестное состояние не подменяется нулём. Обязательные документы, разрешения и блокирующие замечания проверяются отдельно; невыполнение одного такого условия даёт статус «не готова».

Оценка риска. Компоненты приводятся к диапазону от 0 до 1. Отклонение определяется как $D_i = \min(\max(\Delta T_i, 0) / d^*, 1)$, где ΔT_i – разность прогнозируемой и плановой дат, d^* – предельное отклонение проекта. Другие компоненты: F_i – исчерпание временного резерва; $G_i = 1 - K^g_i$ – дефицит готовности; A_i – доля непринятого объёма, равная 1 при блокирующем замечании; Q_i – доля отсутствующих или устаревших обязательных записей. Итоговый индекс:

$$R_i = w_1 D_i + w_2 F_i + w_3 G_i + w_4 A_i + w_5 Q_i, \quad \Sigma_k w_k = 1.$$

В формуле R_i – индекс риска работы i; w_k – неотрицательный вес компонента k, сумма весов равна 1. Индекс служит для сравнения работ, но не является вероятностью нарушения срока. Интерфейс показывает вклад компонентов. Веса и пороги проверяются анализом чувствительности; имитационные методы оставлены для следующего этапа [6].

Расчётный пример. При плане 1000 м на дату контроля выполнено 420 м. Приращения за пять дней равны 55, 60, 0, 65 и 70 м, средний темп – 50 м/день. Остаток 580 м требует 11,6 рабочего дня. До плановой даты девять дней, ожидаемое отклонение – три дня. Для четырёх условий взяты веса 0,35; 0,25; 0,20; 0,20 и состояния 1; 1; 0; 1. Значение Kg_i равно 0,80, а G_i – 0,20. При $D_i = 0,30$, $F_i = 0,40$, $A_i = 0,15$, $Q_i = 0,10$ и весах 0,30; 0,25; 0,20; 0,15; 0,10 индекс R_i равен 0,26.

План проверки. На цепочке «разработка грунта – укладка трубопровода – сварка – обратная засыпка» сопоставляются B_0 – обычный контроль «план – факт», B_1 – прогноз по темпу, B_2 – сетевой прогноз с резервами и B_3 – предлагаемый метод. Для B_1–B_3 рассчитывается ошибка даты завершения; все варианты сравниваются по выявленным просрочкам, ложным предупреждениям и времени предупреждения. Используются только сведения, известные на дату расчёта.

Заключение. Разработан метод ранней оценки риска по данным общей карточки работы. Определены входные показатели, расчёт и обработка пропусков. Архитектура веб-приложения связывает записи ПТО, производителя работ и технического надзора; руководитель получает оценку с указанием причин. Расчётный пример показывает порядок вычислений, но не заменяет проверку на производственных данных. Далее требуется реализовать программный модуль и сравнить варианты B_0–B_3.

Список литературы

1. СП 48.13330.2019. Организация строительства. Актуализированная редакция СНиП 12-01-2004 // Росстандарт: официальный портал. – Текст: электронный. – URL: https://protect.gost.ru/sp/details/278f4ffa-b29b-4733-b8ac-d9a5ff3775cc (дата обращения: 03.10.2026).
2. ISO 19650-1:2018. Organization and digitization of information about buildings and civil engineering works, including building information modelling (BIM) – Information management using building information modelling – Part 1: Concepts and principles. – Geneva: ISO, 2018. – 34 p.
3. Vanhoucke M. A simulation and evaluation of earned value metrics to forecast the project duration / M. Vanhoucke, S. Vandevoorde // Journal of the Operational Research Society. – 2007. – Vol. 58, no. 10. – P. 1361–1374. – DOI 10.1057/palgrave.jors.2602296.
4. Batselier J. Evaluation of deterministic state-of-the-art forecasting approaches for project duration based on earned value management / J. Batselier, M. Vanhoucke // International Journal of Project Management. – 2015. – Vol. 33, no. 7. – P. 1588–1596. – DOI 10.1016/j.ijproman.2015.04.003.
5. Hamzeh F. R. Understanding the role of «tasks anticipated» in lookahead planning through simulation / F. R. Hamzeh, I. Saab, I. D. Tommelein, G. Ballard // Automation in Construction. – 2015. – Vol. 49. – P. 18–26. – DOI 10.1016/j.autcon.2014.09.005.
6. Koulinas G. K. Schedule delay risk analysis in construction projects with a simulation-based expert system / G. K. Koulinas, A. S. Xanthopoulos, T. T. Tsilipiras, D. E. Koulouriotis // Buildings. – 2020. – Vol. 10, no. 8. – Art. 134. – DOI 10.3390/buildings10080134.

УДК 621.311 : 519.8

ЗАДАЧА ВЫБОРА ОПТИМАЛЬНОЙ ТОПОЛОГИИ РАЗОМКНУТОЙ ЭЛЕКТРОСЕТИ

Яр-Мухамедов И.Г., доц.
Институт машиноведения, автоматики и геомеханики НАН КР,
г. Бишкек, Кыргызская республика
aldar@email.su

Введение. Задача оптимизации транспортных потоков является ключевой в аспекте реализации связей производителей и потребителей. Существуют различные подходы к формулировке и решению этой задачи и, в частности, к построению оптимальной топологии сетей доставки материалов и/или энергии с целью сокращения издержек и снижения потерь. Построена классификация подходов к оптимизации топологии сетей. Предложена постановка задачи и модель целочисленного линейного программирования для ее решения.

Цель. Сформулировать задачу выбора оптимальной топологии электросети таким образом, чтобы, во-первых, обеспечить максимальную прозрачность доступность модели для целей обучения и, во-вторых – удобство и интерпретируемость как исходных положений, так и результатов решения задачи для конечных пользователей в процессе эксплуатации.

Основная часть. Классификация моделей, методов и алгоритмов этой задачи может быть представлена в виде следующей структуры.

1. Алгоритмический подход.

1.1. В терминах неориентированных графов

1.1.1. Построение последовательным добавлением кратчайших путей. Алгоритм Дейкстры [1] по поиску кратчайших путей в графе является одним из первых представителей этого семейства алгоритмов. Другим примером может служить алгоритм Краскала [2].

1.1.2. Построение сети последовательным отбрасыванием заведомо неоптимальных путей из исходного множества возможных путей. Этот подход в некотором смысле противоположен и дополняет упоминаемый в предыдущем пункте.

1.2. В терминах ориентированных графов

1.2.1. Алгоритмы построения остовных деревьев. Это направление обычно связывают с именами Чу-Лю [3] и Эдмондса [4]. Но одна из первых ссылок находится у автора работы [2].

1.2.2. Алгоритмы построения основных лесов. Элементы этого подхода имеются в [2], [3] и в ряде других работ.

2. Декларативный подход. Его суть – в математическом описании исходной модели в виде задачи целочисленного или смешанного линейного программирования с логическими переменными (ЦЛП). Здесь

на первый план выступают свойства моделируемого объекта. В качестве метода решения задачи может использоваться подходящий из арсенала имеющихся программных пакетов линейного программирования.

Существует несколько различных моделей ЦЛП для решения данной задачи. Но не смотря на то, что они позволяют находить оптимальные решения, им свойственны, в той или иной мере, определенные недостатки как с точки зрения использования в практике планирования и управления, так и с точки зрения образования.

Во-первых, неоправданно вводятся дополнительные понятия и фиктивные переменные, не имеющие приемлемых интерпретаций в рассматриваемой проблемной области.

Во-вторых, вводятся балансовые ограничения, которые во многих случаях вовсе не необходимы и в ряде постановок просто излишни.

В-третьих, вводятся обратные потоки. Как это понимать специалисту или студенту? Решать общую задачу выбора топологии на основе частного случая, который в нашей формулировке задачи даже и не является таковым, вряд ли имеет смысл.

Исходя из этого предлагается сформулировать задачу на содержательном уровне в терминах, максимально приближенных к предметной области. Следующий этап заключается в том, чтобы представить ее в форме задачи целочисленного линейного программирования с логическими переменными. Отметим, что этапы формализации задачи и непосредственно связанные с ними этапы интерпретации решений [5] играют существенную роль как в эксплуатации программных продуктов, так и обучении их осознанному использованию.

Модель имеет следующие компоненты.

1. Целью решения задачи является выявление топологии сети, имеющей минимальную длину (это не исключает использования иных целевых показателей, таких, например, как временные или денежные издержки). Целевая функция имеет вид:

$$\sum_{i=1}^{N}\sum_{j=1}^{N} d_{ij}x_{ij} -> \min,$$

где: N – общее количество пунктов, включая пункт источника; i, j – индексы пунктов; d_{ij} – расстояния между пунктами с соответствующими индексами (первый – откуда исходит линия, второй – куда заходит); x_{ij} – логические переменные, единичные значения которых показывают, что пункт j соединен линией и получает энергию из или через пункт i.

2. Источник должен иметь, как минимум, одну исходящую линию. Максимальное количество исходящих линий ограничено количеством пунктов-потребителей (M):

$$1 \le \sum_{j=2}^{N} x_{1j} \le M.$$

3. В каждый из пунктов-потребителей входит ровно одна линия:

$$\sum_{i=1}^{N} x_{ij} = 1, \quad j = \overline{2, N}.$$

4. Таким образом, общее количество линий равно количеству пунктов-потребителей:

$$\sum_{i=1}^{N} \sum_{j=1}^{N} x_{ij} = M.$$

Параметрические ограничения:

$$x_{ij} \in \{0,1\}, \quad i = \overline{1, N}, \; j = \overline{1, N}.$$

Для проверки модели использовались решатели lp_solve и glpsol.

Заключение. Простота предложенной модели и доступность свободных решателей позволяют надеяться на более широкое применение методов оптимизации в практике планирования, управления, образования.

Список литературы

1. Dijkstra, E. W. A Note on Two Problems in Connexion with Graphs / E. W. Dijkstra // Numerische Mathematik. – 1959. – Vol. 1. – P. 269–271. URL: https://ir.cwi.nl/pub/9256/9256D.pdf (Дата обращения 18.05.2026 г.).
2. Kruskal, J. B. On the Shortest Spanning Subtree of a Graph and the Traveling Salesman Problem / J. B. Kruskal // Proceedings of the American Mathematical Society. – 1956. – Vol. 7, no. 1. – P. 48–50. doi:10.1090/S0002-9939-1956-0078686-7. URL: https://www.ams.org/journals/proc/1956-007-01/S0002-9939-1956-0078686-7/S0002-9939-1956-0078686-7.pdf?t=1779089562008. (Дата обращения 18.05.2026 г.).
3. Chu, Yeong-Jin. On the Shortest Arborescence of a Directed Graph / Yeong-Jin Chu, Tseng-Hong Liu // Scientia Sinica. – 1965. – Vol. XIV, no. 10. – P. 1396–1400. URL: https://github.com/jungyeul/chu-liu-1965/blob/main/chu-liu-1965.pdf (Дата обращения 18.05.2026 г.).
4. Edmonds, J. Optimum Branchings / J. Edmonds // Journal of Research of the National Bureau of Standards, Section B. – 1967. – Vol. 71B, no. 4. – P. 233–240. doi:10.6028/jres.071b.032. URL: https://doi.org/10.6028%2Fjres.071b.032 (Дата обращения 18.05.2026 г.).
5. Яр-Мухамедов, И. Г. Исследования, разработки и образование / И. Г. Яр-Мухамедов // Философские и методологические проблемы исследования российского общества: Сборник трудов VII Международной научно-практической конференции, Москва, 24 ноября 2023 года. – Москва: Российский университет транспорта, 2023. – С. 233-238. – EDN LBPPFM.

С О Д Е Р Ж А Н И Е

Компьютерные системы и технологии искусственного интеллекта

Абилхан А.С., Косенко О.В. Применение ИИ-алгоритмов улучшения качества изображения в системах компьютерного зрения 7

Аверин Г.В., Звягинцева А.В., Бражников А.Р. Об оценке эффективности процессов развития естественных систем 10

Алджаф Ш.М. Интеллектуальное управление накопителями энергии в центрах обработки данных: от резервного питания к прогнозному срезанию пиковой нагрузки 13

Аль-Текрети А.А. Экстремальная обучающая машина (ELM): архитектура и неитерационный алгоритм обучения 16

Андриян И.В., Андриян О.В. Универсальный нейровычислитель для мобильных роботизированных платформ: концепция, требования и архитектура 19

Анкудинов К.А., Саиег Т.Х. Литвин Д.Б. Анализ проблем многопоточности и примеры их решения 22

Ахмадиев А.К., Юдина А.В., Гибадуллин Р.Ф. Бюджет вычислительных ресурсов подсистемы мониторинга реального времени 25

Бабакина А.А., Беловодский В.Н. Сравнительный анализ оптимизаторов для метода PINN применяемого к уравнению осциллятора 28

Бабич И.В. Особенности алгоритмов оптимизации и формирования функций потерь при нейросетевом решении дифференциальных уравнений 31

Бабошин С.А., Андриян О.В. Сравнение классического и обучаемых с подкреплением алгоритмов предотвращения столкновений для мобильной робототехнической платформы 34

Бондаренко В.В., Позывной Н.К. Система рекомендаций для платформ онлайн-видеоигр 37

Бондаренко В.И. Автоматизация записи поступающих и проведения вступительных испытаний в системе дистанционного обучения Moodle 39

Бондаренко В.И., Калоша А.Г. Автоматическое реферирование и классификация релевантности научных текстов 42

Валитов Р.Р., Юдина А.В., Гибадуллин Р.Ф. Слой аппаратной абстракции и декларативные профили устройств в кроссплатформенном диагностическом программном обеспечении 44

Васильченко А.М., Захаров К.С., Миронова А.В. Использование элементов точного земледелия на ведущих сельскохозяйственных предприятиях Кемеровской области-Кузбасса 47

Выпряжкина А.А., Филонова Е.С. Разработка архитектуры геоинформационной системы пешеходной навигации с учётом факторов безбарьерной городской среды 50

Галатов С.А., Россинская М.В. Генеративное моделирование в инжиниринге состава пищевых продуктов 53

Галимов Б.Р., Сибаева Г.Р. Моделирование вероятности оттока клиентов фитнес-организации с применением машинного обучения 56

Ганциевский А.В., Белоусова В.С. Влияние геометрических параметров аугментации на устойчивость признаков гибридной модели CNN-random forest при бинарной классификации новообразований кожи 59

Дидур Д.А., Максимова А.Ю., Блохин С.В. Математическая модель формирования релевантного корпуса научных публикаций 62

Дрибан В.А., Яркова А.И., Антипенко А.В., Трофимов В.В., Дуброва Н.А. Разработка гибридной нейросетевой модели для прогноза рисков провалообразования 65

Дунаев Р.А. К вопросу интеграции ИИ в системы управления инфраструктурой и безопасностью в университете 68

Дяченко А.С., Тимофеев Б.И., Комендаков Д.И. Системы автоматической проверки фактической достоверности текстов, генерируемых искусственным интеллектом 71

Евдокимова А.Н., Погорелов А.А. Мягкое планирование как подход к проектированию персональных инструментов для студентов с тревожно-депрессивным профилем: опыт дизайн-ориентированного исследования 73

Ермоленко Т.В., Ефимова В.А. Обоснование выбора методов аспектного анализа тональности русскоязычных отзывов о видеоиграх 76

Ермоленко Т.В., Мартынов В.В. Методы глубокого обучения для автоматизированного обнаружения дефектов дорожного покрытия 79

Ефименко К.Н., Савенко М.О. Применение методов машинного обучения для краткосрочного прогнозирования временных рядов в условиях ограниченных данных 82

Зайцева В.А., Губенко Н.Е. Интеллектуальные алгоритмы адаптивной маршрутизации в системе университетской навигации 85

Звягинцева А.В., Бражников А.Р. Сравнительный анализ сложности моделей ИИ по данным OPEN LLM LEADERBOARD 88

Истратова Е.Е., Пересыпкин С.В., Рыжова Л.В. Исследование влияния алгоритмов сжатия на производительность колоночного формата Parquet в распределенной среде Apache Spark 91

Камалова Н.С., Внукова С.В., Евсикова Н.Ю., Матвеев Н.Н., Лисицын В.И. Проблемы идентификации аксиоматики моделей динамики физических процессов в задачах вычислительного эксперимента 94

Караваева Э.А., Ковтун И.И. Применение SQL-запросов в процессе расчета экономической эффективности автоматизированной системы управления технологическими процессами ткацкой фабрики 97

Каюмов А.Ф., Рахимова Г.С. Возможности применения генеративного искусственного интеллекта в компьютерных системах поддержки учебной и научной деятельности технического вуза 100

Клубаев А.С., Стаценко А.А. Факторы, способствующие переходу к концепции Индустрия 5.0 в машиностроении 103

*Ковтун И.И., Жукова М.А., Мутина М.*А. Интеграция фреймворка QT и языка SQL в процессе построения интерфейса автоматизированной системы управления предприятием овощеводства защищенного грунта 106

Ковтун И.И., Малунов Н.Е. Формирование информационно-аналитической основы автоматизированной системы управления многономенклатурным производством 109

Козак Л.Я., Строжевский Д.А. Разработка навигационной карты для мобильных устройств 112

Колодкин В.М., Акеев А.А. Симулятор работы водонагревательной системы 115

Коротеев С.С. Влияние мультимодальных данных экрана и взгляда на распознавание рабочих режимов 118

Котенко В.Н., Коваль Г.Д. Децентрализованное распределение вычислительных заданий в локальной сети для квантово-химических расчётов 121

Котенко В.Н., Королёв А.В. Проектирование и разработка web-ориентированной системы учёта и обработки данных абитуриентов 124

Котенко Ю.В., Гузенко В.С. Автоматизация управления персоналом и бизнес-процессами медицинской клиники на основе веб-ориентированной информационной системы 127

Котенко Ю.В., Кривенчук А.Ю. Проектирование универсальной веб-платформы онлайн-записи и управления услугами с предметно-ориентированной конфигурацией 130

Котенко Ю.В., Лукашева С.Ю. Архитектура интерактивного веб-стенда для моделирования федеративного обучения Edge AI в сетях 6G 133

Кузовков Д.А., Заргарян Е.В. Разработка и исследование IIoT системы мониторинга и энергопотребления оборудования 136

Лакиза А.С. Оптимизация хранения метаданных активности абонентов в сети интернет 139

Латкин В.А. Экосистемный подход в ситуационном моделировании для целей мониторинга окружающей среды 141

Лисина Т.Б., Тумбинская М.В. Критерии выбора нейросетевой модели идентификации объектов для поисково-спасательной системы БПЛА 144

Ломонос Г.Т., Онопко Н.В., Юраш М.И. Анализ задержек и стабильности передачи инерциальных данных по каналу Wi-Fi на базе протокола Modbus TCP в среде Scada Trace Mode 7 147

Лямцев О.А. Методы повышения робастности 3D-оценки позы человека к окклюзиям для анализа двигательной активности 150

Максименко И.И. Контрольные и распознающие эксперименты на пространствах обобщенных автоматов 153

Максименко И.И., Богданов Н.А. Агентный подход к построению интеллектуального ассистента разработчика для конфигураций 1С:Предприятие 156

Максименко И.И., Маликов В.А. Использование глубокого обучения нейросетей для классификации и воспроизведения музыкальных произведений 159

Максимова А.Ю., Лямцев О.А., Чернядьев И.В. Нейросимвольный мониторинг соблюдения промышленных регламентов по видеопотоку 161

Манха О.А., Блохин С.В., Елисеев В.О., Максимова А.Ю., Дидур Д.А. Построение моделей детекторов галлюцинаций в ответах больших языковых моделей 164

Мартыненко А-А.М., Свинцицкая О.С. Разработка автоматизированной информационной системы учёта и анализа деятельности косметологической клиники 167

Мартыненко А-А.М., Тукмачев С.А. Типизированный протокол сообщений как способ обеспечения независимости компонентов интерактивной системы 170

Мартыненко А-А.М., Умецкая Е.А. Анализ использования методов машинного обучения для обнаружения сетевых вторжений..... 173

Мартыненко С.В. Цифровой двойник диагностики газоотводящего тракта дуговой сталеплавильной печи с совещательным контуром машинного обучения 176

Мельникова А.А., Бородин Г.А. Выявление аномальных колебаний фондового индекса методами машинного обучения..... 179

Мельникова А.А., Бородин Г.А. Выявление фишинговых веб-сайтов методами машинного обучения на основе поведенческих признаков 182

Михайлович Е.В., Белоусова В.С. Ускорение разметки панорамных рентгенограмм зубов с применением мультимодальных больших языковых моделей..... 185

Мищук В.В., Бондаренко В.И. Система классификации русскоязычных текстовых сообщений интернет-мессенджеров по категориям риска на основе трансформерных моделей..... 188

Мороз Е.С., Герасимова В.С. От спайковых нейронных сетей к коннектомным моделям зрения в задаче сопровождения объектов 191

Некрасова Д.Р., Лазебная Л.А. Кодирование признаков динамических дактилем русского жестового языка для автоматизированного сравнения 193

Никитенко К.А., Звягинцева А.В. Частотно-адаптивная модель оценки семантической близости слов 196

Никифоров Г.Б., Пименов В.И., Андреев Д.А. Алгоритм включения агрегированных оценок тональности сообщений в модель прогнозирования доходности российских акций 199

Пигуз В.Н., Изосимова С.А., Ивашко К.С., Ковалева К.В., Коваленко И.М., Сальников И.С. Разработка теоретических основ и компьютерных интеллектуальных технологий диагностирования психоэмоционального состояния личности во время стресса военного времени..... 202

Пресняков М.С., Прибыльский А.В. Унифицированный интерфейс модулей как основа масштабируемой архитектуры информационного обеспечения систем контроля технологических процессов 205

Сахаров Р.И., Шипшова О.А. Сравнительный анализ методов промпт-инжиниринга при решении задач большими языковыми моделями..... 208

Сулейманов Д.А., Сементеева Л.Ш. Применение методов машинного обучения для прогнозирования отказов нефтегазового оборудования..... 211

Сычёва И.И. Человеческий капитал в эпоху искусственного интеллекта (ИИ): переосмысление навыков и компетенций..... 214

Тимохин Н.С., Филонова Е.С. Почему ИИ отлично пишет код, но спотыкается на простой математике..... 217

Трофимов В.В., Домарев В.И. Влияние глубины декомпозиции на объём хранения разреженных данных в реляционной базе данных..... 220

Ферубко А.О., Казаков О.Д. Обзор алгоритмов расчёта объёмов оперативной памяти при её перераспределении между виртуальными машинами с учётом ограничений 222

Чекашов Д.Э., Юдина А.В., Гибадуллин Р.Ф. Пороговая цветовая индикация состояния компонентов: гистерезис и подавление дребезга 225

Чернядьев И.В., Ермоленко Т.В. Повышение разрешения цифровых изображений: методы, ограничения, перспективы 228

Шкуркин Д.В. Применение методов машинного обучения для прогнозирования отказов компьютерных систем 231

Шумская В.В., Сенюшкин Н.С. Применение искусственного интеллекта и технологий анализа данных для контроля качества авиационной продукции . 234

Яковлев К.Я., Камальдинова З.Ф. Разработка метода ранней оценки риска нарушения сроков в информационной системе строительного производства . 237

Яр-Мухамедов И.Г. Задача выбора оптимальной топологии разомкнутой электросети 240

НАУЧНОЕ ИЗДАНИЕ

ДОНЕЦКИЕ ЧТЕНИЯ – 2026: ОБРАЗОВАНИЕ, НАУКА, ИННОВАЦИИ, КУЛЬТУРА И ВЫЗОВЫ СОВРЕМЕННОСТИ

Материалы
XI Международной научной конференции,
10–12 ноября 2026 г.,
г. Донецк

ТОМ 2
Физические, технические и компьютерные науки
Часть 2

под общей редакцией проф. *С.В. Беспаловой*

Дизайн обложки	*В. Дёмина*
Технические редакторы	*В.Г. Медведева, М.В. Фоменко*
Компьютерная верстка	*В.Г. Медведева*

Адрес оргкомитета:
ФГБОУ ВО «Донецкий государственный университет»,
ул. Университетская, 24, г. Донецк, 283001, ДНР, РФ.
E-mail: *science.prorector@donnu.ru*

Подписано в печать 28.10.2026 г.
Формат 60×84/16. Бумага офсетная.
Печать – цифровая. Усл.-печ. л. 14,4.
Тираж 50 экз. Заказ № 26окт121/2б.
ФГБОУ ВО «Донецкий государственный университет»
283001, г. Донецк, ул. Университетская, 24.
Издательство ФГБОУ ВО «ДонГУ».
283001, г. Донецк, ул. Университетская, 22.
E-mail: donnu.izdatelstvo@mail.ru