



ПОЛИТЕХ
Санкт-Петербургский
политехнический университет
Петра Великого



ПРОМЫШЛЕННЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ (ПИИ'2025)

Всероссийская научно-практическая
конференция с международным участием
3—4 июля 2025 года

Сборник научных трудов



ПОЛИТЕХ-ПРЕСС
Санкт-Петербургский
политехнический университет
Петра Великого

Санкт-Петербург
2025

Промышленный искусственный интеллект (ПИИ'2025). Всероссийская научно-практическая конференция с международным участием 3–4 июля 2025 г.: сборник научных трудов / под общ. ред. Д. Г. Арсеньева. — СПб. : ПОЛИТЕХ-ПРЕСС, 2025. — 559 с.

Настоящее издание подготовлено Санкт-Петербургским политехническим университетом Петра Великого с целью развития достижений технологий искусственного интеллекта в промышленности. В сборнике научных трудов Конференции доклады представлены в виде полных статей по следующим направлениям: «Программно-аппаратные платформы и технологии искусственного интеллекта в системах автоматизации и управления», «Распределенный и гибридный групповой интеллект в робототехнике», «Предиктивная аналитика и интеллектуальные системы», «Промышленная кибербезопасность».

Сборник трудов адресован научным работникам, инженерам и учащимся вузов, специализирующихся в областях промышленного искусственного интеллекта, интеллектуальных систем и технологий автоматизации, роботизации, управления.

Содержание докладов представлено в авторской редакции.

Министерство науки и образования РФ
Санкт-Петербургское отделение РАН
ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого»
ФГБОУ ВО «Санкт-Петербургский государственный университет»

СОПРЕДСЕДАТЕЛЬ КОНФЕРЕНЦИИ

Арсеньев Дмитрий Германович

Член-корреспондент Российской академии наук, заместитель Председателя СПбО РАН, проректор Санкт-Петербургского политехнического университета Петра Великого, профессор, д-р техн. наук.

Кузнецов Николай Владимирович

Член-корреспондент Российской академии наук, заведующий кафедрой прикладной кибернетики Санкт-Петербургского государственного университета, профессор, д-р. ф.-н. наук.

ПРОГРАММНЫЙ КОМИТЕТ

Бобцов А. А., доктор техн. наук, профессор, декан Мегафакультета компьютерных технологий и управления Университета ИТМО;

Полянский В. А., доктор техн. наук, профессор, директор ИПМаш РАН;

Турчак А. А., президент Союза промышленников и предпринимателей Санкт-Петербурга, президент — генеральный директор ХК «Ленинец», профессор, доктор экон. наук, канд. техн. наук;

Санников Д. О., директор департамента инноваций и цифровых технологий АО «Кольская ГМК» ПАО «ГМК «Норильский никель»»;

Окрепилов М. В., доктор техн. наук, заместитель генерального директора по качеству и образовательной деятельности ВНИИМ им. Д. И. Менделеева;

Хасанов М. М., доктор техн. наук, профессор, директор ПАО «Газпром нефть» по науке;

Белинский А. В., канд. техн. наук, ООО «НИИгазэкономика»;

Куприянов М. С., доктор техн. наук, профессор, Руководитель перспективных проектов ЛЭТИ;

Степанов О. А., доктор техн. наук, профессор, начальник научно-образовательного центра ОАО «Концерн «ЦНИИ «Электроприбор»»;

Зегжда Д. П., член-корреспондент РАН, доктор техн. наук, профессор, директор ИКНК СПбПУ;

Мещеряков Р. В., доктор техн. наук, профессор РАН, директор центра интеллектуальных робототехнических систем ИПУ им. В. А. Трапезникова РАН;

Чернигов Л. М., канд. техн. наук, генеральный директор группы компаний «НПФ «Ракурс»;

Одегов В. Е., генеральный директор АО «Атомик Софт»;

Аксенин С. Г., генеральный директор АО НИЦ «ИНКОМСИСТЕМ»;

Попов С. С., проректор по цифровизации МАИ;

Федоров П. М., руководитель отдела ООО «РЖД-Технологии»;

Ложников П. С., доктор техн. наук, профессор, проректор по науке ОмГТУ;

Кортон С. В., доктор экон. наук, профессор, первый проректор УрФУ им. имени первого Президента России Б.Н. Ельцина.

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ

Шкодырев В. П., доктор техн. наук, профессор, профессор ВШУКС СПбПУ;

Гебель Е. С., канд. техн. наук, доцент, доцент ВШУКС СПбПУ;

Фургат И. Б., доктор техн. наук, профессор, ИПМаш РАН;

Потехин В. В., канд. техн. наук, доцент, доцент ВШУКС СПбПУ;

Селиванова Е. Н., старший преподаватель ВШУКС СПбПУ

ВЫЗОВЫ И ПЕРСПЕКТИВЫ ПРОМЫШЛЕННОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

В начале июля 2025 года Санкт-Петербургский политехнический университет Петра Великого стал центральной площадкой для обсуждения стратегических направлений развития промышленности России, приняв масштабную Всероссийскую научно-практическую конференцию с международным участием «Промышленный искусственный интеллект». Это значимое событие было организовано Санкт-Петербургским отделением РАН на базе Политеха при поддержке ведущих академических институтов и университетов страны.

Конференция объединила более 150 участников из 25 университетов и научных организаций, а также около 20 промышленных предприятий и компаний-разработчиков. География мероприятия впечатляла — от Калининграда до Дальнего Востока, с участием представителей из Беларуси и Китая. Среди участников были ведущие специалисты из СПбПУ, СПбГУ, ИПУ имени Трапезникова РАН, МАИ, МФТИ, ИТМО, ТюмГУ и других признанных научных центров.

Тон всему форуму задал его сопредседатель, член-корреспондент РАН, проректор по международной деятельности СПбПУ Дмитрий Арсеньев, который в своем вступительном слове призвал перейти от абстрактных дискуссий к созданию «сильного» промышленного ИИ — систем, способных управлять структурно сложными объектами в условиях неопределённости. Его мысль развил первый проректор Политеха, член-корреспондент РАН Виталий Сергеев,

отметивший, что именно синергия промышленности, науки и образования приведет к созданию прорывных продуктов, где ИИ станет основой для работы с большими данными.

Научная программа первого дня включила в себя серию блестящих пленарных докладов, где директор по науке «Газпром нефти» Марс Хасанов говорил о гибридных нейросимвольных системах, а представители АО «Кольская ГМК» «Норникель» и «Ракурс-инжиниринга» делились реальным опытом импортозамещения и внедрения ИИ-решений на производстве. Особый интерес вызвал доклад директора Центра интеллектуальных робототехнических систем ИПУ РАН Романа Мещерякова о принципах управления коллективами роботов.

Второй день конференции открывал модератор, член-корреспондент РАН, заведующий кафедрой прикладной кибернетики СПбГУ Николай Кузнецов. В своем выступлении он представил новаторский подход университета к подготовке кадров, рассказав о первом в России специалитете в области математики искусственного интеллекта. Его тему поддержал проректор по цифровизации МАИ Сергей Попов, посвятивший доклад поиску баланса между возможностями больших языковых моделей и академической честностью в образовательном процессе.

Параллельно на молодежной секции студенты и аспиранты СПбПУ, СПбГУ, ИТМО, МАИ и других ведущих вузов страны представили результаты своих исследований в области ИИ, доказав, что у российской науки в этой области есть не только настоящее, но и яркое будущее. Подводя итоги, участники и организаторы единогласно отметили, что конференция стала уникальной площадкой для диалога между наукой, образованием и бизнесом, необходимой для технологического прорыва в столь стратегически важной области, как промышленный искусственный интеллект.

Сопредседатель конференции ПИИ'2025

Д. Г. Арсеньев

ОГЛАВЛЕНИЕ

Вызовы и перспективы промышленного искусственного интеллекта.....	4
---	---

Пленарные доклады

<i>Арсеньев Д. Г., Шкодырев В. П.</i> Сильный промышленный искусственный интеллект: принципы когнитивизма и структурирования знаний в системах управления	12
<i>Мещеряков Р. В.</i> Интеллектуальные робототехнические системы. Общие подходы	23
<i>Чернигов Л. М., Мисюль А. С.</i> Импортозамещение в системах управления и контроля. Вопросы диагностики с использованием искусственного интеллекта на объектах электроэнергетики	31
<i>Санников Д. О., Малыхина Г. Ф., Машьянов К. К.</i> Интеллектуальное управление ТЭЦ на основе многокритериальной оптимизации и модели предсказания	44
<i>Кузнецов Н. В., Абрамов М. В., Алексеева Т. А., Благов М. В., Кудряшова Е. В., Мокаев Р. Н., Мокаев Т. Н.</i> Первый в России специалитет в области математики искусственного интеллекта: наука и индустрия	53
<i>Одегов В. Е.</i> Российская АСУ ТП: технологический суверенитет в промышленной автоматизации.....	65

Секция 1.

«Программно-аппаратные платформы и технологии искусственного интеллекта в системах автоматизации и управления»

<i>Белинский А. В.</i> Гибридные физико-осведомленные модели машинного обучения и нейросимвольный искусственный интеллект — основа цифровых двойников трубопроводных систем энергетики	77
---	----

<i>Ануфриев А. С., Замятин А. И.</i> Интеллектуальная система управления «РАЗУМ»: сквозное управление технологической цепочкой по производству железорудного окатыша	91
<i>Соколов Б. В., Захаров В. В.</i> Методология и технологии автоматизации и интеллектуализации проактивного управления сложными объектами	101
<i>Фарунцев С. Д.</i> Применение методов интеллектуального управления для непрерывных процессов подготовки и переработки нефти.....	112
<i>Тайманов Р. Е., Сапожникова К. В.</i> Измерения и искусственный интеллект. Новый этап	129
<i>Миргородская А. В., Фот Н. П.</i> Нейросетевое моделирование в системе обеспечения единства измерений.....	140
<i>Капырин Н. И., Архипов Н. С., Загорный С. Г.</i> Преобразование нейросетевых алгоритмов в код для микроконтроллера и валидация в модельном окружении на российской платформе ENGEE.....	149
<i>Аминова А. С., Аверич В. Е., Овсянников К. А.</i> Автоматизация метрологической экспертизы стандартов с применением нейронных сетей: архитектура, функциональность и перспективы внедрения	158
<i>Кобыльсков И. П.</i> Безразборная РВС-технология, как одна из составляющих предписательной надежно-ориентированной системы	168
<i>Зуауи П., Санников Д. О., Хохловский В. Н.</i> Предсказательная аналитика расхода пара на металлургическом производстве с использованием нейронных сетей	177
<i>Макарова А. А., Малыхина Г. Ф.</i> Объяснимый искусственный интеллект в системах поддержки принятия решений	187
<i>Соловьева А. А., Малыхина Г. Ф.</i> Организация больших данных для обучения интеллектуальной системы управления ТЭЦ	201
<i>Беднарский А. А., Селиванова Е. Н.</i> Геометрический и кластерный подход к оценке состояния технологического оборудования	209

<i>Го Чэньси, Бахрами А., Потехин В. В.</i> Двухветвевая сверточная нейронная сеть с механизмом выявления закономерностей во входных данных для прогнозирования остаточного ресурса подшипников	218
<i>Ли Цзымин, Ковальчук Е. А., Мишра Анишуман, Потехин В. В.</i> Интерактивный метод диагностики неисправностей на основе больших языковых моделей	228
<i>Шейх Ал Ард МХД Сами, Кожубаев Ю. Н., Потехин В. В.</i> Оптимизация параметров бурения на основе алгоритмов градиентного бустинга и роя частиц	236
<i>Семенов К. К.</i> Оценка погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта	245

Секция 2. Распределенный и гибридный групповой интеллект в робототехнике

<i>Довгополик И. С., Борисов О. И.</i> Интеллектуальная эвристика в задаче планирования движения робототехнических систем	259
<i>Яременко А. М., Захаров Д. Н., Панин А. Д., Алиев Д. Р., Борисов О. И.</i> Интеллектуальное управление коллаборативными мобильными роботами в задачах промышленной автоматизации	270
<i>Курочкин М. А., Тимофеев А. С.</i> Итеративный метод децентрализованного управления формированием роя БПЛА	278
<i>Немчинов А. А., Амелин К. С., Губарев А. А., Серохвостов А. Ю., Соболев Л. А., Соболев С. П., Чернов А. О.</i> Кибериммунитет в беспилотных авиационных системах	287
<i>Бархум М., Живицкий А. Ю., Борисов О. И., Пыркин А. А.</i> Управление мобильным роботом на базе алгоритма TD3 с оценкой вероятностного представления состояния для частично наблюдаемой окружающей среды	298
<i>Зорин В. А.</i> Использование нейросетевых алгоритмов для обнаружения источника пожара с борта БПЛА	308

<i>Чайников Ю. С.</i> Автоматизированная система контроля загрузки грузового транспорта для горно-обогатительных комбинатов с использованием технологий компьютерного зрения, в том числе лидарных технологий	317
<i>Ассалама Л., Потехин В. В.</i> Распознавание движений роботов при выполнении технологических операций	324

Секция 3. Предиктивная аналитика и интеллектуальные системы

<i>Болотов С. В., Крутолевич С. К.</i> Применение искусственного интеллекта для контроля качества контактной точечной сварки	334
<i>Ким Р. В.</i> Оценка технического состояния и прогноз отказов технических систем с использованием вероятностно-гарантирующего подхода	343
<i>Копысова Е. А.</i> Повышение качества регулирования в условиях неопределенности с использованием модифицированных линейных законов управления	354
<i>Мисник А. Е.</i> Применение онтологий на основе мета-ассоциативных графов в задачах промышленного машинного обучения	363
<i>Паращук Д. И., Карякин Ю. Е.</i> Автоматическая генерация 3d-моделей помещений на основе планировок с использованием искусственного интеллекта	373
<i>Арсеньев Д. Г., Мисник А. Е., Шалухова М. А.</i> Кластеризация и предобработка данных в управлении реабилитацией	385
<i>Лень И. А., Чернов А. О.</i> Восстановление сигнала по малому числу наблюдений с не удовлетворяющими традиционным статистическим предположениям помехами	396
<i>Юркевичус С. П., Вражнов Д. А.</i> Методы искусственного интеллекта в задаче автоматизации экспертизы научных проектов	404

<i>Куприянов М. С., Кочетков А. В.</i> Модели самоорганизации для промышленных информационных систем	413
<i>Батиц Е. А., Крайнюченко Я. В., Машьянов К. К.</i> Подготовка инженерно-технических кадров по заказу промышленных предприятий на примере совместного цифрового хакатона	424
<i>Луков А. А.</i> Адаптивная стабилизация с обеспечением заданной точности регулирования	430
<i>Суин А. Е., Серебряков В. О., Чернышева Т. Ю.</i> Использование каскадов моделей для резюмирования встреч	439
<i>Каспицкий А. А., Карякин Ю. Е.</i> Экспериментальный анализ агрессивного поведения на городских видео. От сбора данных до сравнения моделей.....	448
<i>Зуауи П., Шкодырев В. П.</i> Гибридная ансамблевая модель, объединяющая VAR, GRU и XGBoost для прогнозирования энергопотребления	458
<i>Мищенко И. И., Мисник А. Е.</i> Применение сверточных нейронных сетей для автоматической сегментации позвоночника в системах поддержки врачебных решений.....	472
<i>Дербина К. А., Симонов Р. А., Глухих Д. И.</i> Интеллектуальный анализ данных датчиков фальшпола для поддержки принятия решений	482
<i>Георгиев Д., Гебель Е. С.</i> Оценка влияния фильтрации данных на качество параметрической идентификации модели методом дифференциальной эволюции	494

Секция 4.

«Промышленная кибербезопасность»

<i>Гавва Г. Д., Калинин М. О.</i> Киберустойчивость цифровой электроподстанции.....	502
<i>Арсеньев Д. Г., Баскаков Д. Е.</i> Объяснимая runtime-детекция нарушений API-контрактов в микросервисах на основе T-GNN.....	513

<i>Охлопков Н. М., Калинин М. О.</i> Обеспечение целостности глобальной модели федеративного машинного обучения в крупных промышленных интеллектуальных системах с использованием технологии БЛОКЧЕЙН.....	520
<i>Подоров А. А., Полтавцева М. А.</i> Применение временной логики при верификации процессов обработки и хранения больших данных	528
<i>Васильев О. С., Крудышев В. М.</i> Применение модели доверия для повышения защищенности распределенного реестра в информационных системах умного города	535
<i>Ворошин Е. А., Полтавцева М. А.</i> Формирование портфеля решений в управлении информационной безопасностью.....	543
<i>Шкодырев В. П., Баскаков Д. Е.</i> Применение машинного обучения для гибридной верификации надежности программного обеспечения промышленных киберфизических распределенных систем	551

УДК 330.1
doi:10.18720/SPBPU/2/id25-506

СИЛЬНЫЙ ПРОМЫШЛЕННЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ: ПРИНЦИПЫ КОГНИТИВИЗМА И СТРУКТУРИРОВАНИЯ ЗНАНИЙ В СИСТЕМАХ УПРАВЛЕНИЯ

Арсеньев Дмитрий Германович¹, Шкодырев Вячеслав Петрович²

Санкт-Петербургский политехнический
университет Петра Великого, Санкт-Петербург, Россия

¹vicerector.int@spbstu.ru, ²shkodyrev@spbstu.ru

Аннотация. Концепция сильного (общего) промышленного искусственного интеллекта (ИИ) рассматривается с позиции когнитивизма, как основы расширенного функционала систем управления, основанных на знаниях — способных извлекать, накапливать и применять знания, выделенных из скрытых закономерностей причинно-следственных связей в экспериментальных данных при принятии оптимальных управляющих решений. Рассмотрены модели формализации предметных знаний управления и их алгоритмизация графами и гипер-графами знаний. Выделен класс задач управления, обосновывающих потребности формирования сильного промышленного искусственного интеллекта, используемого для формирования «сложных стратегий» решения определенного класса задач управления. Сформирована базовая архитектура интеллектуальной системы управления с ядром, представленным реляционной базой знаний стратегий управления. Прикладной эффект применения сильного промышленного ИИ иллюстрируется на примере решения практических задач управления классами структурно-сложных плохо формализуемых объектов, функционирующих в условиях неопределенности.

Ключевые слова. Сильный искусственный интеллект, когнитивные системы, интеллектуальные системы управления, реляционные базы знаний.

Введение

Неизменно большой интерес, вызываемый темой искусственного интеллекта (ИИ) в самых широких кругах общества, заставляет специалистов задуматься не только о широком спектре возможных потенциальных направлениях его применения, но и корректности научного обоснования применяемых решений, эффективности и достоверности получаемых результатов, строгости и корректности критериев оценки таких результатов. Особенно актуально научное обоснование понятия и ключевых положений ИИ, его реальных возможностей, степени и диапазона возможностей, как надежной технологии, становится для решения инженерных задач промышленности, энергетики, транспорта, других ключевых отраслей народного хозяйства [3].

Когнитивные способности как основа интеллектуализации

По мнению многих специалистов наиболее перспективным и проблемным направлением, связанным с возможностями современной теории ИИ является понятие сильного ИИ, который в большинстве работ ассоциируется с термином «General Artificial Intelligence» [7, 9–10,13]. Одно из первых упоминаний термина «сильный искусственный интеллект» (General Artificial Intelligence) появилось более сорока лет назад — в 1980 году, его связывают с работой Джона Серла (John Searle) [14]. В его работе был описан мысленный эксперимент с «китайской комнатой», в котором запрограммированный компьютер с нужными входами и выходами рассматривается как разум в контексте наиболее сильного человеческого интеллекта или разума. Однако анализ большого числа современных научных публикаций свидетельствует, что к настоящему времени нет устоявшегося общепринятого понятия «сильного» ИИ. В работах по анализу концепции сильного ИИ показаны

такие перспективные направления его применения, как моделирование возможностей рассуждения в системах (problem solving and reasoning) [7], методы глубокого обучения и самобучения (deep learning and unsupervised / self-learning) [9], решение общих сложных проблем промышленности (general problem solving) [10]. Можно сказать, что в большинстве работ сильный искусственный интеллект в настоящее время рассматривается как гипотетический вид ИИ, который обладает способностью к обобщённому мышлению, сопоставимой с человеческим интеллектом [15]. И в отличие от слабого, который обучен выполнять ограниченный класс конкретных задач, сильный должен решать любые интеллектуальные задачи, понимать контекст, адаптироваться к новым условиям и обучаться без ограничений [12]. Однако большинство работ при интерпретации сильного интеллекта сходятся к его интерпретации с позиции когнитивных возможностей систем (cognitive systems), как систем, оперирующих понятием «знания».

Обобщая анализ большинства приведенных и существующих работ, можно сделать вывод, что именно сильный ИИ, обладающий присущими ему общими когнитивными способностями понимать, обучаться и применять знания в широком спектре задач, подобно человеку, позволяет оценить наиболее привлекательные перспективы и практическую значимость результатов, получаемых от внедрения ИИ, особенно в наиболее важных и критических для общества — промышленных приложениях. Резюмируя в данном контексте принцип когнитивизма, формируется его понимание как ключевого механизма в интеллектуализации систем управления, как систем, основанных на знаниях, и составляющих основу мыслительных способностей [1]. Именно способность извлекать, накапливать и применять знания для реагирования на изменяющиеся условия или поведение объекта управления составляют основу теории и практики использования понятия искусственного интеллекта в системах управления [5,12]. И именно знания в понимании, оценивании и принятии оптимальных управляющих решений становятся основой интеллектуализации систем промышленной автоматизации, роботизации и управления.

Онтологический подход к структурированию знаний управления

Онтологический подход к формализации понятия «знаний», и в частности — предметных знаний теории управления, рассматривает онтологию как способ структуризации предметных знаний, абстрактных или специфических, в какой-либо предметной области, реализованный на основе формального описания объектов (сущностей) E , фактов F и отношений R между ними:

$$O = \langle E, R, F \rangle.$$

В данном представлении онтология рассматривается как семантически структурированная основа представления предметных данных, базирующаяся на логике и включающая терминологический словарь и набор объектов сложной структуры и специфические отношения между ними [2].

Более детализированной основой формализации для концептуализации представления знаний управления является графовая модель, и в частности — граф знаний, отражающий семантическую структуру онтологии взаимосвязей между сущностями и логикой преобразований или реагирования, кодируемых вместе с соответствующими данными с помощью таксономий и онтологий, определяемых триадой [6]:

$$G = \{ \mathcal{E}, \mathcal{R}, \mathcal{F} \}$$

в которой сущности $\mathcal{E}$ определены как конечный набор понятий предметной области онтологии знаний, задающие текущее состояние объекта или процесса управления, соответствующую реакцию $\mathcal{F}$ системы управления на данное состояние объекта, и связь $\mathcal{R}$ между текущим состоянием и действием системы управления на это состояние соответственно, как модель управления $\mathcal{R} = \{r_1, r_2, \dots, r_{N_r}\}$. При этом для множества возможных состояний $\mathcal{E} = \{e_1, e_2, \dots, e_{N_e}\}$ и соответствующую реакцию на них $f \in \mathcal{F}$ можно интерпретировать как множество стратегий реагирования на текущее состояние объекта управления, формально задаваемых кортежем $(h, r, f) \in \mathcal{F}$, интерпретирующим стратегии реагирования (управления) через отношения $\mathcal{R} = \{r_1, r_2, \dots, r_{N_r}\}$.

Рассматривая граф знаний как онтологически структурированную модель, сочетающую семантику скрытых причинно-следственных связей в экспериментальных данных, и вскрывающую отношения между сущностями предметной области, под фактом, задаваемым кортежем $\mathcal{F}$ следует понимать «модель реагирования» или «модель принятия решения» (управления). Тогда знания управления можно представить как отношения $r \in \mathcal{R}$ для состояний объекта управления h с выбранной моделью реагирования $t \in \mathcal{T}$, обозначающее стратегию перевода этих состояний из текущего в желаемое целевое через оператор:

$$f \rightarrow \pi(X, Y, U),$$

в котором под $\pi(X, Y, U)$ понимается выбранная стратегия управления. Такой подход делает удобными для алгоритмизации знаний стратегий управления графовой моделью, отражающей выделения семантической основы скрытых закономерностей в данных, базирующаяся на логике и включающая терминологический словарь и набор утверждений о моделируемых объектах.

Для сложно-структурированных системных взаимосвязей, в которых отношения $\mathcal{R}$ между сущностями $\mathcal{E}$ предметных знаний теории управления и фактами $\mathcal{F}$ могут иметь сложно-соподчиненную иерархическую структуру, граф знаний $\mathcal{G}$ трансформируется в гипер-граф [6]. Такой гипер-граф знаний $\mathcal{HG}$ также можно интерпретировать как структурированную в виде графа базу знаний, задаваемую кортежем

$$\mathcal{HG} = \{\mathcal{E}, \mathcal{R}, \mathcal{F}\},$$

в котором факты $\mathcal{F}$ о мире — объектах предметной области знаний управления хранятся в виде отношений $\mathcal{R}$ между двумя или более сущностями $\mathcal{E}$ [8, 11].

Реляционная база знаний в архитектуре ИСУ

Знания формируются в процессе обучения, а обучение проводится на реальных экспериментальных данных. При этом обязательным и ключевым этапом является подготовительный этап

структурирование данных, целью которой является сохранения в них семантики причинно-следственных связей между сущностями и фактами, определяющих правил реагирования. Формально объект, обрабатываемый в реляционных базах данных, представляет отношение (связи). В «знаниях управления» такие «связи-отношения» задают связи между данными «вход-выход-управление».

Процесс трансформации обучающей выборки, представленной в реляционных базах данных в базу знаний, основан на формальной интерпретации понятия отношений между данными D_i , реляционная база которых может быть представлена формой

$$R \subseteq D_1 \times D_2 \times \dots \times D_n,$$

и которые в простейшем случае можно определить как множество констант, связанных отношениями, в новую форму отношений —

$$k \in T \subseteq K_1 \times K_2 \times \dots \times K_n,$$

между более сложными сущностями K_i , к которым можно отнести множество условий, правил, понятий или функциональных отношений [15]. В более детальной интерпретации, когда данные обучения $\langle D_1, \dots, D_i \rangle$ представлены набором деревьев — графами в базисе исчисления древовидных структур $\mathbf{D}: D_i \subseteq D$, отношения между сущностями K_i следует интерпретировать как множество условий, правил, понятий, которые связываются отношениями моделей графодинамики как сущностями «знания управления» [4]. Формальное описание отображения некоторых «сущностей состояния» объекта управления в форме вектора состояния $\mathbf{X}_{s_k}$, в атрибут $\mathbf{Y}_{s_{k+1}}$ сущности «целевое / промежуточное состояние» S_{k+1} в базисе искусственных нейронных сетей можно рассматривать как итерацию

$$\mathbf{Y}_{s_{k+1}} = f(\mathbf{W}_{s_k} \mathbf{X}_{s_k}),$$

реализующую отношение «оператор управления» с матрицей параметров $\mathbf{W}_{s_k}$. Таким образом, формирование понятия «реляционная база знаний» (РБЗ), можно рассматривать как объединении двух базовых понятий: реляционной базы данных, определяющей экспери-

ментальные реляционные данные параметров текущего состояния объектов управления), связанных отношениями $\mathcal{R}$, и определенного («достаточно специфического») / множества функциональных моделей / функциональных зависимостей / $\mathcal{F}$, задающих способ извлечения и формирования (накопления) моделей зависимостей – стратегии отображения (преобразования) одних реляционных множеств данных (отношений) в новые «отношения знаний управления» [11].

Применение сильного промышленного ИИ в решении прикладных задач управления

Прикладной эффект применения сильного промышленного ИИ в системах управления в докладе иллюстрируется на примере решения задачи управления структурно-сложным плохо формализуемым производственным процессом в условиях неопределенности по критериям многоцелевой многокритериальной оптимизация иерархии взаимосвязанных технологических комплексов.



Рис. 1. Обобщенная структура реляционной базы знаний ИСУ оптимизации процессов управления




Рис. 2. Результат оптимизации процессов управления генерацией теплоносителя (на примере работы парового котла): а – до оптимизации, б – после оптимизации, в – лепестковая диаграмма визуализации динамики параметров управления

На рис. 1 показана обобщенная структура основных компонент базы знаний интеллектуальной системы управления со стратегиями Парето-оптимизации, а на рис. 2 — экспериментальные результаты применения разработанной интеллектуальной системы управления с интеллектуальной базой знаний стратегий многоцелевой иерархической Парето-оптимизации процессов управления генерации теплоносителя в режиме непрерывного управления сбалансированным теплоснабжением.

Заключение

Научный подход к проблеме применения ИИ в различных областях промышленного предполагает наличие строгого корректного обоснования концепции и принципов когнитивизма как перспективной методологии решения классов сложных производственных задач. Именно когнитивные возможности систем в формировании формальных моделей знаний о скрытых причинно-следственных связях, выделенных из реальных экспериментальных данных, могут дать объективную информацию, расширяющую возможности систем искусственного интеллекта.

В то же время необходимо помнить, что существует ряд ограничивающих условий эффективности его применения, среди которых в первую очередь следует выделить необходимость корректности и строгости обоснования поставленной цели для решаемой задачи, исключающие неоднозначность получаемого результата, наличие достаточной и достоверной статистики хорошо структурированных обучающих данных, объективные критерии количественного и качественного оценивания выбранной стратегии и достигнутого результата, некоторые другие. Без их учета использование данных технологий не позволит гарантировать желаемого эффекта.

Библиография

1. Артамонов В. А. Артамонова Е. В., Милаков А. С. Когнитивизм как база искусственного интеллекта // Управление наукой: теория и практика. Т.6, №2, 2024.

2. Гаврилова Т. А. Базы знаний интеллектуальных систем / Т. А. Гаврилова, В.Ф. Хорошевский. — СПб.: Питер, 2000. — 384 с.

3. ГОСТ Р 59277-2020. Национальный стандарт Российской Федерации. Системы искусственного интеллекта. Классификация систем искусственного интеллекта. М.: Стандартинформ. 2021.

4. Затуливетер Ю. С. Компьютерный базис сетцентрического управления. Труды конференции «Технические и программные средства систем управления, контроля и измерения», М., Октябрь 2010.

5. Станкевич Л. А. Когнитивные системы и роботы. ПОЛИТЕХ-ПРЕСС, СПб., 2019.

6. Bahare Fatemi, Perouz Taslakian, David Vazquez, and David Poole. Knowledge hypergraphs: Prediction beyond Binary relations, In IJCAI , 2021. 2191–2197.

7. Ben Goertzel. Artificial General Intelligence: Concept, State of the Art, and Future Prospects, Journal of Artificial General Intelligence 5(1) 1-46, 2014. DOI: 10.2478/jagi-2014-0001;

8. Galkin M., Priyansh Trivedi, Gaurav Maheshwari, Ricardo Usbeck, and Jens Lehmann. Message passing for hyper-relational knowledge graphs. In EMNLP, 2020. 7346–7359.

9. Jiao Chen, etc. Towards General Industrial Intelligence: a Survey of Continual Large Models in Industrial IoT, arXiv:2409.01207v2 [cs.LG] 27 Dec 2024.

10. Jayesh Rane, etc. Artificial general intelligence in industry 4.0, 5.0, and society 5.0: Applications, opportunities, challenges, and future direction. Deep Science Publishing, https://doi.org/10.70593/978-81-981271-0-5_6 ;

11. Murakami, M., Yokota, H., Itoh, H. Formal Semantics of a Relational Knowledge Base // ICOT Technical Report TR-149., December 1985.

12. Perlovsky L. I., Shkodyrev V. P. Physics of Mind – A Cognitive Approach to Intelligent Control Theory // Lecture Notes in Networks and System, 95, Cyber-Physical Systems and Control, Springer, 2020.

13. Kumpulainen S., Terziyan V. Artificial General Intelligence vs. Industry 4.0: Do They Need Each Other? // Proceedia Computer Science 200 (2022). P. 140–150.

14. Searle, John. R. (1980) Minds, brains, and programs. Behavioral and Brain Sciences 3 (3): 417-457.

15. Yokota, H., and Itoh, H. A Model and Architecture for a Relational Knowledge Base // ICOT Technical Report TR-144, Proceedings of the 13th Znternational Symposium on Computer Architecture, 2–9, June 1986.

STRONG INDUSTRIAL ARTIFICIAL INTELLIGENCE: PRINCIPLES OF COGNITIVISM AND KNOWLEDGE STRUCTURING IN CONTROL SYSTEMS

Dmitry G. Arseniev¹, Viacheslav P. Shkodyrev²

Peter the Great St. Petersburg Polytechnic University,
St. Petersburg, Russia

¹vicerector.int@spbstu.ru, ²shkodyrev@spbstu.ru

Abstract. The concept of strong (general) industrial AI is considered from the standpoint of the principles of cognitivism as the basis for the expanded functionality of knowledge-based control systems – the ability to extract, accumulate and apply knowledge from hidden patterns of cause-and-effect relationships in experimental data when making optimal management decisions. The models of the formalization of pre-metric management knowledge and their algorithmization by graphs and hypergraphs of knowledge are considered. A control tasks class is identified that substantiate the needs for the formation of a strong industrial artificial intelligence used to form “complex strategies” for solving a certain class of management tasks. The basic architecture of an intelligent management system with a core represented by a relational knowledge base of management strategies has been formed. The applied effect of using strong industrial AI is illustrated by the example of solving precise tasks of managing classes of structurally complex poorly formalized objects operating under conditions of uncertainty.

Keywords. Strong (general) artificial intelligence, cognitive systems, intelligent control systems, relation knowledge base.

* * *

УДК 004.896
doi:10.18720/SPBPU/2/id25-507

ИНТЕЛЛЕКТУАЛЬНЫЕ РОБОТОТЕХНИЧЕСКИЕ СИСТЕМЫ. ОБЩИЕ ПОДХОДЫ

Мешеряков Роман Валерьевич

Институт проблем управления им. В. А. Трапезникова
Российской академии наук, Москва Россия

mrvt@ipu.ru

Аннотация. Современные робототехнические системы представляют собой сложные системы, объединяющие мехатронную, энергетическую и программную составляющие. Задачи управления и степень их детализации зависит от среды функционирования, структуры, степени автономности, сенсорного обеспечения, интерфейсов управления, коммуникационных каналов связи, вычислительных блоков обработки данных и других характеристик робототехнических систем. Общие подходы к управлению и повышению интеллектуализации робототехнических систем заключаются не в замене классических алгоритмов управления интеллектуальными, а в использовании генеративных технологий искусственного интеллекта для повышения степени их автономности и функционирования.

Ключевые слова. Робототехника, искусственный интеллект, интеллектуализация, управление.

Введение

Развитие современных технологий позволяет существенно изменить ландшафт применения робототехнических систем [1]. Активно развиваются направления, связанные с физическими принципами на основе фотоники – формируется новый класс киберфизических систем. Вместе с тем остаются открытыми вопросы создания и использования методов управления такого класса систем, в том числе с повышением интеллектуализации

Общие подходы

На рис. 1 показан модель построения системы управления, которая предполагает наличие двух составляющих: объекта и систе-



Рис. 1. Модели системы управления

мы управления [3]. Следует отметить, что для построения и оценки системы управления требуется построение соответствующих моделей как объекта, так и самой системы управления.

В свою очередь для реализации в робототехнических комплексах модель управления можно представить в виде совокупности нескольких взаимосвязанных блоков, представленных на рис. 2. Необходимо отметить, что в отличие от «классических» систем управления, в которых присутствует аналитическое описание как модели, так и системы управления в предлагаемом подходе может быть использован и подход с наличием системы управления, которая представляет собой систему управления «обученной по данным».

Таким образом могут быть использованы интеллектуальные методы обработки данных, в том числе, методы искусственного интеллекта и машинного обучения. На рис. 1 показан модель построения системы управления, которая предполагает наличие двух составляющих: объекта и системы управления [3]. Следует отметить, что для построения и оценки системы управления требуется




Рис. 2. Декомпозиция системы управления

построение соответствующих моделей как объекта, так и самой системы управления.

Робототехнические системы (РТС) представляют собой сложные системы, объединяющие механическую (мехатронную), энергетическую (электрическую, гидравлическую, пневматическую, механическую или их комбинаций) и программную (в самом широком смысле) составляющей. Совершенствование робототехнических систем идет по всем перечисленным составляющим как в части использования новых технологий и материалов, так и в части взаимодействия составных частей РТС и повышения интеллектуализации поведения РТС [4].

Робототехнические системы и их интеллектуализация

Робототехнические имеют различную среду функционирования, структуру, степень автономности, сенсорное обеспечение,

интерфейсы управления, коммуникационные каналы связи, вычислительные блоки обработки данных и других характеристики. Например, мобильные РТС развивались от дистанционно-управляемых машин до полностью автономных, которые функционируют в недерминированной среде.

Дистанционно-управляемые машины предназначены для выполнения действий с использованием средств передачи команд управления через среду на различных физических принципах от человека к РТС и его исполнительным механизмам. Как правило, человек наблюдает за действиями РТС и ставит задачи различной степени детализации — от команд на конкретные двигатели и схваты, так и укрупненно — взять предмет или переместиться на определенное расстояние.

Повышение автономности РТК проводится в направлении постановки более абстрактных и крупных задач, таких как, перемещение в определенное место, проведение мониторинга, патрулирование района, сбор урожая, опрыскивание растений, построение карты. Задачи состоят из последовательности элементарных действий, которые могут быть однозначно интерпретированы и формализованы. При возникновении нештатных ситуаций РТС переводится в режим останова и ожидает принятия управляющих решений со стороны человека-оператора.

Увеличение количества сенсоров позволяет еще увеличить степень автономности и начать принимать некоторые простые решения с более широкой вариативностью. Типовым решением является формирование полетных заданий для беспилотных летательных аппаратов — задаются координаты промежуточных точек и действия, которые необходимо выполнять при прохождении участка траектории и/или на промежуточной или итоговой точке, при этом траекторное управление выполняется в автоматическом варианте.

Самая высокая степень автономности предполагает, что РТС обладает всей необходимой информацией для принятия решений в условиях неопределенности. К автономным автомобилям предъявляются требования по автономности SAE [5].

Переходя к среде функционирования следует отметить, что у каждой среды есть свои характеристики. Особенности воздушной среды определяются самой средой функционирования: конструктивно используются различные аэродинамические схемы, которые, как правило, сводятся к самолетному или мультикоптерному типу, либо комбинированные схемы типа конвертоплана. Вместе с тем все беспилотные летательные аппараты (БПЛА) являются частью беспилотной авиационной системы (БАС) [6].

Отметим, что в целом БАС включает в себя не только БПЛА, но и наземную инфраструктуру, каналы связи между ними, а также людей. Это формирует единую сложную крупномасштабную систему, в которой беспилотные летательные аппараты являются лишь небольшой, хотя и важной частью.

Первой задачей, которая ставится перед системой управления БПЛА — это формирование полетного задания и загрузка его на борт БПЛА. При его выполнении требуется использование различных интеллектуальных алгоритмов коррекции полетного задания при его выполнении на различных этапах. Очевидно, что учет характеристик внешней среды — метеорологические условия, динамические препятствия, проблемы со связью и пр. Интеллектуальность определяется вариативностью алгоритмов принятия решения при различных ситуациях. [6]

Другой задачей, требующей интеллектуализации — это определение местоположения БПЛА в различных системах координат, в которых представлено полетное задание. Сигналы ГНСС, как правило, обладают невысокой точностью, но достаточные для перемещения в воздушной среде, а также могут быть использованы более точные датчики для локализации, например, РТК (Real Time Kinematic) [7]. При перемещении в закрытых пространствах требуется еще большая точность и могут использоваться сенсоры на основе лидаров и других систем технического зрения [8].

В отличие от БПЛА наземные робототехнические комплексы, как правило, имеют возможность больший энергетический ресурс, а также соответствующие вычислительные возможности. Это позволяет использовать более сложные интеллектуальные методы

управления. Известные методы SLAM представляют собой комбинацию интеллектуальных методов получения, обработки, хранения и передачи информации. Это чрезвычайно актуально для отработки сценариев поведения различных транспортных средств на полигонах.

РТС, ориентированные на работу в водной среде, разделяются на безэкипажные катера (БЭК) и необитаемые подводные аппараты — автономные (АНПА) и телеуправляемые (ТНПА). Особенность водной среды определяется наличием течений, различных плотностей, различной прозрачностью что формирует отдельную задачу по позиционированию в водной среде. На рис. 3 представлен подводный аппарат, который может управляться дистанционно, а также предусматривает возможность использования интеллектуальных алгоритмов.




Рис. 3. Телеуправляемый подводный аппарат «Водяной» (ИПУ РАН)

Межсредные роботы представляют собой РТС, которые функционируют в разных средах. Так, возможность переходить из воздушной среды в водную представлена классом БПЛА типа аквадрон, а между землей и водой — амфибиями. Указанное направление нередко решается использованием различных актуаторов на РТС что, с одной стороны, приводит к расширению сред, однако вносит конструктивные решения, которые снижают общую эффективность функционирования в каждой из сред.

Необходимо отметить, что часто человек самостоятельно управляет РТС за счет дополнительных пультов и получает обратную связь зрительным каналом. Имеются и альтернативные способы управления и восприятия информации с РТС [9]. Создание и развитие технических средств взаимодействия с РТС, включая интерфейсы и гибридный интеллект будет развиваться как со стороны человека — как приспособление, так и путем интеллектуализации технологий.

Заключение

Рассмотренные общие подходы к робототехническим системам и повышению их интеллектуализации не ограничены заменой классических алгоритмов управления интеллектуальными. Перспективным представляется использование генеративных технологий искусственного интеллекта для повышения степени автономности и функционирования РТС.

Библиография

1. Мешеряков Р. В. Интеллектуальные робототехнические системы // Датчики и системы. 2024. № 2 (274). С. 12–17.
2. Сойфер В. А. и др. Киберфотоника // Самара, Новая техника 2025. 248 с.
3. Теория управления (дополнительные главы): Учебное пособие / Под ред. Д. А. Новикова. — М.: ЛЕНАНД, 2019. — 552 с.
4. Meshcheryakov R. Control of hyperlinked cyber-physical systems // Smart Innovation, Systems and Technologies. 2020. Т. 154. С. 27–33.

5. SAE Levels of Driving Automation <https://www.sae.org/blog/sae-j3016-update>.

6. **Кутахов В. П., Мещеряков Р. В.** Управление групповым поведением беспилотных летательных аппаратов: Постановка задачи применения технологий искусственного интеллекта // Проблемы управления. 2022. № 1. С. 67–74.

7. **Вольф Д. А., Александров В. А., Резков И. Г.** Автоматизация поведения пилота БПЛА с применением отечественного микроконтроллера // Промышленные АСУ и контроллеры. 2023. № 3. С. 9–16.

8. **Мамченко М. В., Зорин В. А., Романова М. А.** Эмпирическая модель расчета затухания сигнала с учетом коэффициента застройки местности для беспилотных транспортных средств // Известия Кабардино-Балкарского научного центра РАН. 2022. № 1 (105). С. 59–72.

9. **Мещеряков Р. В., Туровский Я. А.** Гибридный искусственный интеллект для использования в управлении техническими средствами // В сборнике: XIV Всероссийское совещание по проблемам управления. сборник научных трудов. Москва, 2024. С. 3232–3235.

INTELLIGENT ROBOTIC SYSTEMS. COMMON APPROACHES

Roman V. Meshcheryakov

V. A. Trapeznikov Institute of Control Sciences
of Russian Academy of Sciences., Moscow, Russia

mrv@ipu.ru

Abstract. Modern robotic systems are complex systems that combine mechatronic, energy, and software components. Control tasks and the degree of their detail depend on the operating environment, structure, degree of autonomy, sensor support, control interfaces, communication channels, computing data processing units and other characteristics of robotic systems. General approaches to control and increasing the intellectualization of robotic systems do not consist in replacing classical control algorithms with intelligent ones, but in using generative artificial intelligence technologies to increase their autonomy and functioning.

Keywords. Robotics, artificial intelligence, intellectualization, control.

* * *

УДК 004.032:57.087.1

doi:10.18720/SPBPU/2/id25-508

ИМПОРТОЗАМЕЩЕНИЕ В СИСТЕМАХ УПРАВЛЕНИЯ И КОНТРОЛЯ. ВОПРОСЫ ДИАГНОСТИКИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ОБЪЕКТАХ ЭЛЕКТРОЭНЕРГЕТИКИ

Чернигов Леонид Михайлович¹, Мисюль Андрей Сергеевич²

ООО «Ракурс-инжиниринг», Санкт-Петербург, Россия

¹chernigov@rakurs.com, ²misiul@rakurs.com

Аннотация. Рассмотрены актуальные вопросы использования искусственного интеллекта в системах автоматизации, контроля и регулирования. Представлены перспективные направления развития предиктивных систем диагностики основного оборудования электростанций, основанные на данных стационарных систем автоматизации, построенных на базе программно-технических комплексов «Апогей» и «Енисей». Описаны основные дефекты и диагностические признаки необходимые для машинного обучения и создания цифровых моделей энергетического оборудования.

Ключевые слова. программно-технический комплекс, машинное обучение, цифровая модель, искусственный интеллект, предиктивная диагностика.

Введение

ООО «Ракурс-инжиниринг» является лидером в области исследований, разработки и внедрения систем управления и контроля для электроэнергетики в России и странах Центральной Азии. За более, чем 30-летнюю историю компания разработала и внедрила около 2000 систем управления и контроля на ГЭС, ТЭС и АЭС различного масштаба. Инфраструктура компании, её компетентный персонал, позволяют вести исследования, разработку и производство современных комплексных систем автоматизации с учетом требований Указа Президента Российской Федерации от 30.03.2022 г. № 166 «О мерах по обеспечению технологической независимости и безопасности критической информационной

инфраструктуры Российской Федерации», направленного на импортозамещение и информационную безопасность объектов критической инфраструктуры и энергетики, в частности. В компании ведется активная разработка, производство и внедрение систем автоматизации на базе программно-технических комплексов (ПТК) «Апогей» и «Енисей».

Оба комплекса были разработаны и созданы, как продукты импортозамещения и полностью соответствуют Постановлению Правительства Российской Федерации от 17.07.2015 г. № 719 «О подтверждении производства российской промышленной продукции». При этом ПТК «Апогей» используется для построения комплексных систем управления и контроля таких как: АСУ ТП котлоагрегата, АСУ ТП турбоагрегата, АСУ ТП блока, АСУ ТП гидроагрегата, АСУ ТП ГЭС и т.п. ПТК «Енисей» применяется при создании систем контроля мониторинга и диагностики для гидроагрегата.

Традиционно для построения полномасштабной АСУ ТП организации человеко-машинного интерфейса взаимодействия с оператором или диспетчером, отображения производственного процесса, накопления данных и их анализа используют SCADA – системы (верхний уровень АСУ ТП). В компании разработана и внедрена SCADA – система, созданная, как импортозамещающий продукт на отечественной платформе, называется этот продукт «Раскада», зарегистрирован в реестре российского программного обеспечения Министерства цифрового развития, связи и массовых коммуникаций Российской Федерации.

Также в рамках программы импортозамещения в компании были разработаны, производятся электронные модули для измерения ряда физических величин таких как: вибрация, температура, частота вращения, сопротивление изоляции и др. Данные модули используются для построения систем управления и контроля, имеют функциональные возможности и характеристики, которые отличают их от аналогичных приборов: возможность работы в мощном электромагнитном поле и при высоком уровне помех, высокую точность измерений, надежность и безопасность.

Таким образом, на сегодняшний день «Ракурс-инжиниринг» благодаря собственным инвестициям в разработку ПТК и SCADA – системы, а также в разработку и производство электронных модулей, реализует проекты комплексной автоматизации со 100% импортозамещением.

Исполнение требований 719 ПП РФ, направленных на развитие технологического суверенитета страны, создает благоприятные условия для импортозамещения в промышленности в целом и внедрения отечественных систем автоматизации и контроля, в частности.

Инвестиции в научно-исследовательские и опытно-конструкторские работы (НИОКР) позволяют компании сохранять лидирующие позиции на рынке, разрабатывать новые продукты и улучшать существующие системы. Это обеспечивает не только конкурентные преимущества, но и способствует устойчивому развитию всей отрасли.

Сервисный центр «Ракурс-инжиниринг» выполняет весь комплекс работ по сопровождению автоматизированных систем управления в течение всего жизненного цикла, обеспечивает квалифицированное обслуживание, качественное функционирование и увеличение срока службы систем. Анализируя основные потребности клиентов и состояние автоматизированных систем управления, компания предлагает индивидуальные решения для обеспечения надежного функционирования систем.

Наличие собственного учебного центра в компании позволяет проводить обучение технического персонала промышленных предприятий безопасной и надежной эксплуатации систем автоматизации. Учебный центр оснащен современным оборудованием и учебными материалами, что обеспечивает высокое качество образовательного процесса. Центр имеет лицензию на образовательную деятельность. В рамках учебного процесса проводятся как теоретические занятия, так и практические, позволяющие обучающимся не только освоить теоретические аспекты работы с системами автоматизации, но и получить практические навыки их эксплуатации и обслуживания.

ИИ в системах автоматизации

Сегодня активно обсуждаются вопросы использования ИИ в системах автоматизации, контроля и регулирования. Наиболее перспективным видится использование машинного обучения (рис. 1), связанного с созданием алгоритмов и моделей, которые обучаются на данных и создают прогнозы или решения.

Суть метода состоит в том, что на основании архивных данных за значительный период работы (не менее нескольких месяцев) с помощью математических методов обработки строится цифровая модель объекта (котел, турбина, генератор), которая представляется как некоторый эталон. Данные для построения должны быть выбраны из периодов заведомо нормальной работы оборудования таким образом, чтобы охватить максимально возможное количество различных режимов работы и весь диапазон нагрузок. После построения модели проводится сравнение теку-




Рис. 1. Анализ данных и машинное обучение




Рис. 2. Пример онлайн диагностики оборудования электростанции

щих показателей с модельными и, в случае значительных отклонений, формируется сигнализация об обнаружении аномалии. На первых этапах работы аномалия рассматривается и анализируется вручную специалистами, которые дают заключение о её причинах. Информация с ответами специалистов накапливается и на её основании формируется еще одна или несколько моделей, автоматически анализирующих возникающие отклонения и определяющих их причину.

Таким образом, современные методы обработки данных и машинного обучения позволяют получить дополнительный эффект от накопленных архивов информации о работе оборудования.

В частности, прогноз состояния оборудования (рис. 2) осуществляется не на общих правилах, а на базе анализа поведения конкретной единицы оборудования за прошедший период и сравнении результатов с эталонными значениями. Такой подход позволяет определить аномальные отклонения с учетом текущего режима работы, выявить долгосрочные тренды в изменении состояния и, в перспективе, спрогнозировать развитие тех или иных отклонений и неисправностей.

Наиболее значимыми результатами внедрения описываемых методик могут стать:

1. Раннее выявление негативных отклонений в работе оборудования.

2. Прогноз развития дефекта до предупредительных или аварийных состояний.

3. Быстрое определение места и характера отказа и, как следствие, сокращение времени простоя оборудования.

4. Выявление неизвестных ранее закономерностей в работе оборудования и использование их для повышения эффективности.

Возможны различные сценарии применения методик, но все подразумевают наличие некоторого архива информации о работе объекта за продолжительный период времени. На базе этой информации методами машинного обучения могут быть построены различные модели (выявление аномалий, классификация, прогнозирование развития).

Сценарий системы онлайн-диагностики состоит в том, что разработанные модели включаются в эксплуатацию непосредственно на объекте и в реальном времени получают его данные. Таким образом, информация о возникающих отклонениях сразу становится доступна персоналу объекта.

В сценарии офлайн-диагностики (рис. 3) подход иной — модели работают удаленно, данные в них самостоятельно загружаются персоналом по мере необходимости отдельными фрагментами. Результатом работы модели является отчет о найденных отклонениях в загруженных данных, их возможных причинах и прогнозе развития. Такой подход значительно упрощает внедрение систем предиктивной диагностики, т. к. не требует капитальных затрат на оборудование. Может быть первым шагом в направлении к использованию искусственного интеллекта.

Применительно к электроэнергетике мы видим необходимость создания инструментальных средств машинного обучения для следующих применений:

1. Предиктивная диагностика состояния гидроагрегата на основе данных стационарной системы вибрационного контроля



Рис. 3. Пример офлайн диагностики оборудования электростанции

(состояние генераторного и турбинного подшипника, механические и электрические небалансы, состояние вала гидроагрегата, состояние креплений крышки турбины и др.).

2. Предиктивная диагностика состояния турбогенератора на основе данных системы технологического контроля (система охлаждения генератора, конструктивные узлы, состояние изоляции, прогноз мощности и др.).

3. Диагностика состояния регулирующих органов паровой турбины на основе данных системы регулирования и защит.

4. Самодиагностика и настройка регулятора гидротурбины с использованием цифровой модели системы регулирования (прогноз параметров регулирования с помощью ИИ).

Рассмотрим, более подробно, каким образом определение неисправностей гидроагрегатов на основании информации о вибрационном состоянии, получаемой с помощью стационарных систем вибрационного контроля, может быть реализовано средствами искусственного интеллекта.

Повышенная вибрация узлов гидроагрегатов в установившихся режимах вызывается наличием возмущающих сил, дефектами изготовления и сборки, а также дефектами способствующих воз-

никновению резонансных явлений и автоколебаний [1, 2]. Силы, вызывающие вибрацию опорных конструкций гидроагрегатов, разделяются на механические, гидравлические, электрические. Механические возмущающие силы возникают в результате неуравновешенности вращающихся масс гидроагрегата (небаланс ротора гидрогенератора, рабочего колеса турбины). К этому же приводят нарушения центровки, излом линии вала, неперпендикулярность зеркальной поверхности диска подпятника линии вала гидроагрегата и волнистость зеркальной поверхности диска подпятника, увеличенные зазоры в подшипниках и т.д. Характерным признаком наличия механических возмущающих сил является повышенный уровень вибрации опорных конструкций во всех эксплуатационных режимах при обычных уровнях вибрации сердечника статора гидрогенератора [3]. Характерным признаком наличия механического небаланса является линейная зависимость горизонтальной вибрации корпусов направляющих подшипников от квадрата частоты вращения ротора гидроагрегата в режиме холостого хода без возбуждения или в режиме выбега в том числе с освобожденной от воды камерой рабочего колеса [4].

Гидравлические возмущающие силы возникают в результате появления вихревых шнуров в направляющем аппарате и отсасывающей трубе, а также ударного входа потока на лопасти рабочего колеса гидротурбины, несимметричного подхода потока по окружности рабочего колеса и т.д.

Пульсация давления в проточной части и вибрация опорных конструкций от гидравлических возмущающих сил может вызываться также плохим обтеканием отдельных частей сооружений при входе потока в спиральную камеру, различием углов установки лопастей, а также отклонением комбинаторной зависимости от оптимальной.

Характерным признаком наличия гидравлических возмущающих сил является отсутствие вибрации при работе гидроагрегата в режиме синхронного компенсатора с освобожденной от воды камерой рабочего колеса или снижение уровня вибрации в режимах с пуском атмосферного или сжатого воздуха в камеру рабочего ко-

леса. Если такие режимы не предусмотрены, то признаком наличия гидравлических возмущающих сил может служить значительное изменение уровней вибрации при различных режимах работы, в том числе увеличение вибрации при открытии направляющего аппарата.

Электрические возмущающие силы возникают в результате неравномерности воздушного зазора гидрогенератора из-за неправильной формы ротора, его эксцентricности относительно оси вращения или витковыми замыканиями в катушках полюсов.

Спектральный состав низкочастотной полигармонической составляющей вибрации в этом случае зависит от концентричности расположения полюсов ротора или числа полюсов с короткозамкнутыми витками (как правило, это полигармоническая вибрация, включающая обратную составляющую и ее первые пять гармоник).

Характерным признаком наличия электрических возмущающих сил является повышенный уровень низкочастотной вибрации сердечника и корпуса статора гидрогенератора в режимах холостого хода с возбуждением и нагрузки при низких уровнях вибрации на холостом ходу без возбуждения.

Основные дефекты изготовления и сборки относятся к линии вала, а также к таким дефектам подпятника как неперпендикулярность зеркальной поверхности диска оси вала гидроагрегата и неровность зеркальной поверхности диска подпятника. Дефекты линии вала обычно приводят к повышенным значениям биения вала у направляющих подшипников во всех режимах работы гидроагрегата и могут приводить к повышенным горизонтальным вибрациям направляющих подшипников. Неперпендикулярность или волнистость зеркальной поверхности диска подпятника приводит к повышенной вертикальной вибрации опоры подпятника. Эти неисправности также могут вызывать повышенное биение у нижнего генераторного и турбинного подшипника и являться причиной повышенной горизонтальной вибрации.

Диагностирование узлов агрегата с применением стационарной системы вибрационного контроля, может быть выполнено в объеме, указанном в табл. 1.

Таблица 1

Состав диагностируемых параметров гидроагрегата

Узел агрегата	Параметры
Рабочее колесо	Механический небаланс. Гидравлический небаланс. Задевание рабочего колеса за неподвижные части лабиринтного уплотнения. Поломка лопастей (появление трещин).
Лабиринтное уплотнение рабочего колеса	Разрушение лабиринтного уплотнения. Искаженная форма лабиринтного уплотнения.
Турбинный подшипник	Ослабление крепежа корпуса подшипника. Повышенный зазор вал-вкладыш. Неравномерная жесткость корпуса подшипника. Неравномерность жесткости вкладыша подшипника. Ухудшение состояния поверхностей трения сегментов или облицовки вала. Повреждение опорных элементов сегментов подшипника.
Ротор генератора	Механический небаланс. Электрический небаланс. Ослабление посадки обода на спицы ротора генератора. Неточная установка ротора в расточке статора генератора. Неудовлетворительная форма ротора генератора. Появление короткозамкнутых полюсов. Ослабление посадки втулки ротора генератора.
Статор генератора	Ослабление крепления стыков железа статора. Неудовлетворительная форма статора. Ослабление активного железа статора.
Генераторный подшипник	Ослабление крепежа корпуса подшипника. Повышенный зазор вал-вкладыш. Неравномерная жесткость корпуса подшипника. Неравномерность жесткости вкладыша подшипника. Ухудшение состояния поверхностей трения сегментов или облицовки вала. Повреждение опорных элементов сегментов подшипника.

Окончание табл. 1

Подпятник	Волнистость зеркальной поверхности диска подпятника. Неперпендикулярность плоскости пяты к оси вала агрегата. Излом линии вала во фланцевом соединении. Неравномерная нагрузка на сегменты подпятника. Повреждение опорных элементов сегментов подпятника. Ухудшение состояния поверхностей трения сегментов или зеркала пяты.
-----------	---

Аналогичным образом могут быть построены цифровые модели для реализации других, вышеперечисленных задач предиктивной диагностики с использованием искусственного интеллекта на объектах электроэнергетики.

Для турбогенераторов на основе данных системы технологического контроля средствами искусственного интеллекта могут быть диагностированы:

1. Статор: механические повреждения изоляции, увлажнение изоляции межфазных зон, ослабление креплений стержней в лобовой части, различные повреждения конструктивных элементов узлов креплений, элементов выводов и соединительных шин и др.

2. Ротор: замыкания и повреждения витков обмотки, повреждение изоляции токопровода, тепловое старение изоляции обмотки, прогиб и смещение вала и др.

3. Щеточно-контактный аппарат: загрязнения и перегревы контактного кольца, трещины и износы контактных колец, искрение и повреждение изоляции и др.

4. Масляные уплотнения: повреждение уплотнений подшипников, перегрев уплотнений подшипников, повреждение и износ баббита вкладыша, нарушение работы системы маслоснабжения и др.

5. Охлаждение: повреждение конструктивных элементов газоохладителей, течи трубопроводов, повреждения уплотнений и др.

Заключение

Диагностика состояния регулирующих органов паровой турбины на основе данных системы регулирования и защит обеспечит поиск неисправностей в системе регулирования, которые приводят к ухудшению точности и стабильности поддержания регулируемых параметров. Средствами искусственного интеллекта может быть диагностирована работа регулирующих клапанов и сервомоторов, проведен анализ нагрузочной и расходной характеристики турбины и сделаны выводы о её работе.

Очевидно, что без качественных измерений в реальном времени невозможно выполнять адекватную диагностику. Точки контроля, типы первичных преобразователей, измеряемые параметры, необходимые и достаточные для работы искусственного интеллекта, должны определять только специалисты в автоматизации, проектировании и эксплуатации оборудования. Необходимо также, учитывать условия работы измерительного оборудования на объекте эксплуатации, которые отличаются от идеальных условий испытательных лабораторий. Должны выполняться мероприятия по защите от помех электромагнитной природы. Такие помехи могут вносить существенные искажения в измеряемые сигналы, что приводит к некорректной работе всей системы контроля и диагностики. Точно измеренные параметры в необходимом количестве служат основой для достоверной диагностики.

В ООО «Ракурс-инжиниринг» накоплен большой опыт создания систем контроля и мониторинга состояния турбо и гидрогенераторов, систем регулирования гидро и паровыми турбинами. Мы обладаем необходимыми технологиями и компетенциями, позволяющими осуществить сбор и хранение данных о работе энергетического оборудования, получаемых в результате работы наших систем. Приглашаем ВУЗы и специализированные отраслевые организации к совместной работе, направленной на разработку и реализацию современных отечественных методов обработки данных и машинного обучения.

Библиография

1. Временные методические указания по мониторингу и контролю вибрационного состояния гидроагрегатов, оснащённых стационарными системами вибродиагностики. ПАО «Росгидро». URL: https://www.hydropower.ru/lib/catalog/detail.php?list_id=55&element_id=10687.
2. СТО РусГидро 02.02.106–2019. Гидроагрегаты. Автоматизированный мониторинг и диагностирование. Функциональные технические требования.
3. Новоселов В. Б., Шехтер М. В., Кляйнрок И. Ю. Алгоритмы самодиагностики современных систем регулирования и парораспределения паровых турбин // Электрические станции, 2024.
4. Романов И. В. Ремонт по состоянию. Современные методы диагностики турбогенераторов // Энергетик, 2020.

IMPORT SUBSTITUTION IN CONTROL AND MONITORING SYSTEMS. ISSUES OF DIAGNOSTICS USING ARTIFICIAL INTELLIGENCE AT ELECTRIC POWER PLANTS

Leonid M. Chernigov¹, Andrey S. Misyul²

JSC “Rakurs-Engineering”, Saint Petersburg, Russia

¹chernigov@rakurs.com, ²misiul@rakurs.com

Abstract. The current issues of the use of artificial intelligence in automation, control and regulation systems are considered. Promising directions for the development of predictive diagnostic systems for the main equipment of power plants based on data from stationary automation systems based on the Apogee and Yenisei software and hardware complexes are presented. The main defects and diagnostic features necessary for machine learning and the creation of digital models of power equipment are described.

Keywords. Software and hardware complex, machine learning, digital model, artificial intelligence, predictive diagnostics.

* * *

ИНТЕЛЛЕКТУАЛЬНОЕ УПРАВЛЕНИЕ ТЭЦ НА ОСНОВЕ МНОГОКРИТЕРИАЛЬНОЙ ОПТИМИЗАЦИИ И МОДЕЛИ ПРЕДСКАЗАНИЯ

Санников Дмитрий Олегович^{1,а}, Малихина Галина Федоровна^{2,б},
Машьянов Константин Кириллович^{2,в}

¹АО «Кольская горно-металлургическая компания» г. Мончегорск,
Россия ², Санкт-Петербургский политехнический
университет Петра Великого, Санкт-Петербург, Россия

^аSannikovDO@kolagmk.ru, ^бmalyhina_gf@spbstu.ru,
^вmashyanov_kk@spbstu.ru

Аннотация. Эксплуатация крупных промышленных объектов обычно характеризуется несколькими ключевыми критериями: производительность, эффективность, воздействие на окружающую среду. Для достижения оптимального управления такими объектами используются автоматизированные системы, использующие многокритериальную оптимизацию. Критерии рассчитываются на основе информации, непрерывно поступающей с датчиков и хранящейся в промышленной базе данных. Предлагаемый метод основан на нейросетевых алгоритмах моделирования систем объекта, генетических алгоритмах построения границы Парето и рекуррентных нейронных сетях прогнозирования целевых показателей на основе принципа убывающего горизонта. Построенные на данных модели позволили осуществлять многокритериальное управление на основе прогнозирования. Модель была протестирована на данных измерений тепловых электростанций с несколькими котлоагрегатами.

Ключевые слова. ТЭЦ, многокритериальная оптимизация, модель предиктивного управления, нейронные сети, алгоритм NSGA-II.

Введение

Теплоэлектроцентральный (ТЭЦ) вырабатывает электрическую и тепловую энергию, которая поступает в централизованные системы отопления жилых зданий и в промышленные системы для обеспечения производственных процессов в цехах предприятий. Обес-

печение энергоэффективности процессов производства тепла и его промышленного использования является важной задачей для современного производства. ТЭЦ должна работать в оптимальном режиме, учитывая все изменения, вызванные сменой сезона, погоды, а также перестройкой технологических процессов в цехах предприятий. Решение этой задачи должно быть основано на прогнозировании потребления тепла с целью снижения производства избыточного тепла, оказывающего негативное воздействие на окружающую среду. Прогнозирование на относительно короткий период времени позволяет учитывать изменения потребления тепла, связанные с кратковременными изменениями потребления в цехах или сезонными изменениями. Прогноз на коротком временном горизонте может быть выполнен с помощью линейной или нелинейной модели временного ряда. Долгосрочные изменения, связанные с планами производства, например, с введением новых технологических процессов, или с плановым завершением технологических процессов, с плановым ремонтом котельных агрегатов должен быть основан на моделях долгосрочного прогнозирования. При всех прогнозируемых изменениях потребления тепла его производство должно быть оптимальным.

В крупномасштабных производственных системах должно быть несколько критериев оптимальности, которые отражают важнейшие свойства ТЭЦ – производительность, себестоимость производства и влияние на окружающую среду. Критерии должны быть представлены прямо или косвенно измеримыми величинами, образующими вектор целей. Таким образом, задача управления производством тепловой энергии на ТЭЦ является многокритериальной и использующей прогнозирование. Многокритериальная оптимизация позволяет организовать многомерный статистический процесс управления.

В настоящее время многие публикации [1-3] посвящены преимуществам управления на основе моделей прогнозирования, называемый Model Predictive Control (МРС). МРС, который используют ведущие производители, является перспективным методом управления производством теплоносителя ТЭЦ в реальном вре-

мени, так как позволяет прогнозировать будущие состояния системы путем оптимизации целей управления на горизонте прогнозирования с учетом ограничений системы. Система управления пополняется новыми измерениями, и оптимизация повторяется на каждом временном шаге. Нахождение множества допустимых решений для многокритериальной оптимизации основано на максимизации или минимизации целевой векторной функции, состоящей из нескольких критериев [4, 5]. При оптимизации характеристик технологических процессов на производстве целевая функция является сложной для аналитической задачи, она зависит от взаимосвязанных параметров, которые изменяются со временем из-за изменения режимов работы. Использование методов машинного обучения и нейронных сетей для моделирования и предсказания технологических процессов имеет ряд преимуществ, поскольку позволяет моделировать нелинейные процессы, учитывает физику тепловых процессов и данные, характеризующие текущие изменения в ТЭЦ.

Создавая умное производство АО «Кольская горно-металлургическая компания» (КГМК) заботится об устойчивом развитии, которое играет важную роль для современного общества. Устойчивое развитие фокусируется на экономическом развитии, чистоте окружающей среды и благополучии общества. Промышленные экосистемы КГМК стремятся значительно увеличить выработку тепла, сократить потери и уменьшить влияние на окружающую среду. Устойчивая промышленная экосистема действует подобно цепной реакции, улучшая многие аспекты жизни общества. Именно поэтому компании апробируют различные подходы по созданию самых оптимальных метрик оптимизационных решений на производстве.

МРС для управления ТЭЦ

МРС представляет собой метод управления на основе моделей, который включает внутреннюю модель для прогнозирования состояний системы, оптимизацию целей управления на горизонте

прогнозирования с учетом системных ограничений и использование принципа удаляющегося горизонта

Модель МРС предназначена для прогнозирования расхода теплоносителей на коротком и длинном горизонте. Информация для прогнозирования поступает от датчиков и измерительных систем регистрируемая более чем 60 датчиками и накапливаемая в промышленной базе данных (ПБД). Данные ПБД могут содержать аномальные результаты измерений, вызванных сбоями и неполадками в измерительных и коммуникационных системах, поэтому прогностические модели построены на основе устойчивых к аномалиям нейросетевых моделей, основанных на данных, дополнительно подвергающихся нелинейной фильтрации.

Для предсказания используем математическую модель нелинейной динамической системы в пространстве состояний. На вход системы подается вектор параметров управления $u(n)$ в дискретном времени n , на выходе системы наблюдаем вектор результатов измерений $y(n)$; вектор параметров $x(n)$ характеризует состояние объекта в момент времени n . В следующий момент времени $n + 1$ вектор состояния принимает значение $x(n + 1)$, $\Phi(\cdot)$ – нелинейная вектор-функция.

$$x(n + 1) = \Phi(W_A x(n) + W_B u(n)), \quad (1)$$

$$x(n) = C_x(n)$$

Используя уравнение (1), можно получить уравнение, характеризующее предсказание следующих значений параметров $y(n + q)$ состояния системы путем реализации последовательности управляющих воздействий $u(n)$, $u(n + 1)$, ..., $u(n - q - 1)$ на горизонте q :

$$y(n + q) = \psi[y(n), y(n + 1), \dots, y(n + q - 1), u(n), u(n + 1), \dots, u(n + q - 1)]. \quad (2)$$

Уравнение (2) реализует рекуррентная нейронная сеть – многослойный персептрон. В каждый дискретный момент времени персептрон вычисляет последовательность приращения управляющих переменных $\Delta u(n|n)$, $\Delta u(n + 1|n)$, ..., $\Delta u(n - q - 1|n)$ на

горизонте управления q . Задачей прогнозирующего управления является поддержание выхода $\hat{y}(n+1)$, $i = 1, \dots, q$ вблизи заданной опорной траектории таким образом, чтобы избежать больших изменений в сигналах управления и удовлетворить возможные жесткие ограничения на состояния и на входы. Минимизирование ошибок управления относительно предсказанных значений на горизонте управления и ограничение величин управляющих воздействий:

$$J(n) = \sum_{p=1}^N \sum_{n=1}^{n_y} \psi_{p,n} (y_n(n+p) - \hat{y}_n(n+p))^2 \quad (3)$$

В более сложных случаях для MPC используют рекуррентные нейронные сети с долгой кратковременной памятью (LSTM), которые предназначены для обработки гораздо более длинных последовательностей. Сеть LSTM имеет систему вентилей, которая управляет потоком информации, причем на каждом цикле данные контролируются блоком забывания. Система скрытых блоков LSTM с линейными связями называют блоками с утечкой.

МСО-MPC для управления ТЭЦ

МСО-MPC для управления ТЭЦ в режиме реального времени включает многокритериальную оптимизацию, многокритериальное принятие решений и принцип отступающего горизонта. МСО использует алгоритм сортировки данных без доминирования (NSGA-II) для поиска оптимальных по Парето решений в условиях конфликтующих целей. В нашем случае показатели производительности котлоагрегатов, потери тепла и количеств выбросов вредных веществ в окружающую среду являются конфликтующими. Стремление повысить производительность приводит к некоторому увеличению потери и увеличению выбросов. Оптимальное управление позволяет повысить производительность при минимизации потерей и выбросов.

Для оптимизации применением принцип определения оптимальной последовательности сигналов управления по прогнозу

на удаляющемся горизонте. Оптимальная граница Парето может быть статической, построенной по архивным данным, или может изменяться с течением времени. В этом случае на каждом временном шаге управления реализуется только первое управляющее воздействие, после которого система переходит к следующему шагу. Поэтому реализация NSGA-II в формулировке MPC требует критерия принятия решения для выбора предпочтительного решения на каждом этапе управления. Для этой задачи методы многокритериального принятия решений (МСО) используются для выбора предпочтительного решения из множества Парето-оптимальных решений.

Экспериментальные результаты

Данные ПБД были использованы для исследования метода МСО-MPC управления несколькими котлоагрегатами ТЭЦ, обеспечивающими теплом производственные цеха. Для эффективной работы предприятия каждый котлоагрегат должен работать в оптимальном режиме, поэтому принцип управления основан на многокритериальной оптимизации, выполняемой в реальном времени с учетом своевременной смены режимов с использованием прогнозирования будущего потребления.

Для эффективной работы ТЭЦ необходимо, чтобы каждый котлоагрегат работал в оптимальном режиме, определяемом несколькими критериями, характеризующими производительность, к.п.д. и количество вредных выбросов в атмосферу. Каждый котлоагрегат должен быть выведен на границу Парето. К сожалению, в настоящее время в базах данных отсутствует информация о выбросах вредных веществ в атмосферу, что не позволило использовать данный критерий оптимизации.

Для оптимальной совместной работы трех котлоагрегатов необходимо настроить режим каждого котла таким образом, чтобы при их совместной работе была достигнута граница Парето. Такой подход позволяет определить, целесообразно ли вводить в эксплуатацию простаивающий котлоагрегат или лучше перевести уже




Рис. 1. Пространство целевых функций при совместной работе котлоагрегатов

работающие котлоагрегаты на более интенсивный режим работы. В качестве примера на рисунке 1 в пространстве целевых функций отображены режимы работы одного из котлоагрегатов, полученные при обработке данных измерений. Если его производительность недостаточна для работы ТЭЦ, то, выбрав точку на границе Парето, соответствующую совместной работе нескольких котлоагрегатов (рис. 1), можно получить целевые точки на границах Парето для каждого котлоагрегата (рис. 2), который необходимо включить в работу в составе группы.

Заключение

Показано, что данный подход позволяет находить компромиссное решение многокритериальной задачи управления с использованием показателей производительности и эффективности работы ТЭЦ. Преимуществом является то, что модели получены на основе непрерывного измерения параметров котла в течение всего времени работы. Нейросетевые модели котлоагрегатов аппроксимируют зависимость критериев от параметров управления и позволяют получать точки как в пространстве решений, так и в пространстве целей. Метод МСО-MPC может быть дополнен показателями, характеризующими концентрацию вредных выбросов в окружающую среду. Классические рекуррентные сети хорошо предсказывают на относительно коротком удаляющемся горизонте. В случае существенных изменений технологических процессов целесообразно использовать вентильные нейронные сети, например LSTM. Лицо, принимающее решение, может наглядно оценивать компромиссы и сравнивать различные правила управления.

Библиография

1. J. Chen, G. Tian, and Y. Fu. "A novel multi-objective tuning strategy for model predictive control in trajectory tracking", J Mech. Sci. Technol. vol. 39, no. n3, pp. 6657–6667, 2023. doi: 10.1007/s12206-023-1137-7.

2. J. Xu, L. Xu. “Efficiency-Oriented MPC: Using Nested Structure to Realize Optimal Operation and Control”, Mathematics, vol.3, no.10, June 2022 Art. no. 2324. doi.org/10.3390/math10132324.

3. L. Lu, H. Zhao, X. Liu, C. Sun, X. Zhang, H. Yang. “MPC-ECMS Energy Management of Extended-Range Vehicles Based on LSTM Multi-Signal Speed Prediction”, Electronics, vol. 12, May 2023, Art. no. 2642. doi.org/10.3390/electronics12122642.

4. D. Arsenyev, G. Malykhina, V. Shkodyrev. “Industrial Process Control Using DPCA and Hierarchical Pareto Optimization”. Processes no. 11, Nov. 2023, Art. no.3329, doi.org/10.3390/pr11123329.

5. D. Ya. Chaveliparambil, G. F. Malykhina. “Network models for control of industrial ecosystem”, (in Russian), collection of scientific papers of the XXVII International scientific and practical conference, Oct. 2024, Available, <http://elib.spbstu.ru/dl/2/id24-156>.

INTELLIGENT CONTROL OF THERMAL POWER PLANT BASED ON MULTI-CRITERIA OPTIMIZATION AND PREDICTION MODEL

Dmitry O. Sannikov^{1,a}, Galina F. Malykhina^{2,6}, Konstantin K. Mashyanov^{2,b}

¹JSC “Kola Mining and Metallurgical Company”, Monchegorsk, Russia

²Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

^aSannikovDO@kolagmk.ru, ⁶malykhina_gf@spbstu.ru,

^bmashyanov_kk@spbstu.ru

Abstract. Operation of large industrial facilities is usually characterized by several key criteria: productivity, efficiency, impact on the environment. To achieve optimal control of such facilities, automated systems using multi-criteria optimization are used. The criteria are calculated based on information continuously received from sensors and stored in the industrial database. The proposed method is based on neural network algorithms for modeling the facility's systems, genetic algorithms for constructing the Pareto frontier, and recurrent neural networks for forecasting target indicators based on the principle of a decreasing horizon. The models built on these data allowed for multi-criteria control based on forecasting. The model was tested on measurement data from thermal power plants with several boiler units.

Keywords. Thermal power plants, multi-criteria optimization, predictive control model, neural networks, NSGA-II algorithm.

* * *

УДК 51.378.4

doi:10.18720/SPBPU/2/id25-510

ПЕРВЫЙ В РОССИИ СПЕЦИАЛИТЕТ В ОБЛАСТИ МАТЕМАТИКИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: НАУКА И ИНДУСТРИЯ

Кузнецов Николай Владимирович^{1,a}, Абрамов Максим Викторович^{1,26},
Алексеева Татьяна Анатольевна^{1,3в}, Благоев Михаил Валерьевич^{1,г},
Кудряшова Елена Владимировна^{1,д}, Мокаев Руслан Назирович^{1,е},
Мокаев Тимур Назирович^{1,ж}

¹ Санкт-Петербургский государственный университет,
Санкт-Петербургское отделение РАН,

²ПАО Сбербанк, ³Национальный исследовательский университет
Высшая школа экономики

^ankuznetsov239@mail.ru, ⁶m.abramov@spbu.ru, ^бtalekseeva@hse.ru,

^гm.blagov@spbu.ru, ^дe.kudryashova@spbu.ru, ^еr.mokaev@spbu.ru,

^жt.mokaev@spbu.ru

Аннотация. Прогресс в разработке новых моделей и архитектур искусственного интеллекта (ИИ) как ключевой фактор технологического лидерства в области ИИ требует подготовки специалистов элитного кластера в области математики ИИ. Анализ современных образовательных программ в области ИИ ведущих вузов РФ показывает преимущество специалитета для формирования завершеного фундаментального ядра математических основ ИИ и преодоления пробелов, возникающих при разрыве обучения в связке бакалавриат-магистратура.

Ключевые слова. Технологическое лидерство, искусственный интеллект, математика, информатика, высшее образование, специалитет, ФГОС среднего образования.

Введение

Задачи достижения технологического лидерства в ИИ, поставленные в Национальной стратегии развития искусственного интеллекта на период до 2030 года [1], и конкуренция в секторе ИИ существенно изменили структуру рынка труда и требования к об-

разованию и квалификации в этой ключевой отрасли. Основные запросы по использованию ИИ-технологий в индустрии и других секторах экономики, включая государственные и социальные сервисы, сферу услуг, а также производства и обработки информации, фокусируются на автоматизации и оптимизации процессов, связанных с рутинными операциями, контролем и прогнозом критических режимов работы [2]. Использование ИИ в производстве, особенно в крупных промышленных корпорациях, имеет ряд трудностей, связанных в первую очередь с ресурсными ограничениями для масштабного интегрирования ИИ в производственный цикл, например, для полной его автоматизации и роботизации, а также отсутствием единой метрики эффективности от внедрения ИИ. Поэтому производственные проекты с ИИ реализуются в рамках отдельных сегментов предприятий и бизнеса. Например, успешно развиваются направление цифровых двойников для моделирования производственных и бизнес-процессов, платформы видеоаналитики для контроля состояния оборудования, соблюдения технологии процессов, предотвращения аварийных ситуаций и ряд других приложений ML-технологий. При этом текущий спрос на специалистов, решающих задачи массовой разработки отдельных прикладных решений ИИ, не удовлетворен и будет продолжать расти в течение нескольких лет, поэтому сохраняется задача обеспечения значительного притока прикладных специалистов, занимающихся настройкой существующих моделей ИИ, их дообучением и сопровождением жизненного цикла разработки. Решение этой важной задачи возможно при соединении научных результатов и прикладных решений, которые естественным образом реализуются в образовательно-научно-индустриальном партнерстве. В нашей стране есть успешные примеры таких коллабораций. Например, АО «Концерн «ЦНИИ «Электроприбор», который обладает мощной научной и производственной базой, ведет работу со школьниками, студентами, аспирантами, имеет базовые кафедры в ведущих вузах Санкт-Петербурга, в том числе в Санкт-Петербургском политехническом университете Петра Великого. Примерами успешных федеральных проектов являют-

ся образовательно-научно-индустриальные программы Сбера, Т-Банка, Яндекса. В то же время, ближайшее будущее несомненно ассоциировано с качественным прогрессом в сфере ИИ: продвижением в создании новых архитектур и алгоритмов машинного обучения, основанных на них прорывных технологий, широким внедрением этих разработок в индустрию и интеллектуально-емкие области. Другой перспективной задачей является разработка теоретической базы для исследования ИИ с точки зрения правильной интерпретации результатов работы современных и будущих моделей и алгоритмов, что поможет точнее прогнозировать деятельность ИИ и улучшать производительность алгоритмов. Для решения этих прорывных задач необходимы специалисты, обладающие глубокими фундаментальными знаниями в области математики и информатики. Эффективная подготовка такого элитного кластера специалистов может быть реализована только в условиях непрерывного увеличенного периода базового обучения в университете для формирования завершеного фундаментального ядра математических основ ИИ (разделы фундаментальной и прикладной математики, теоретической информатики).

В настоящий момент создалась уникальная возможность использовать разнообразие и гибкость системы образования в нашей стране [3], чтобы расширить спектр имеющихся уровней образования (средняя школа, бакалавриат, магистратура, аспирантура) в области ИИ специалитетом по математике ИИ, который дает существенные преимущества как в подготовке специалистов для новейших научных и технологических разработок в ИИ, так и в решении прикладных задач в сложных наукоемких специальностях и индустрии. Этому также способствуют новые школьные ФГОС 2022 [4], которые формируют пререквизиты для дисциплин ИИ и позволяют реализовать сквозной подход: школа-специалитет-аспирантура/академия/индустрия без разрыва обучения в тандеме бакалавриата и магистратуры.

Мотивация и постановка задачи

В 2021 году в РФ начал реализовываться федеральный проект «Искусственный интеллект» [5] национальной программы «Цифровая экономика Российской Федерации», направленный на ускоренное развитие технологий ИИ и их широкое внедрение в экономику. Существенный акцент был сделан, в том числе, на стимулирование научных исследований в этой области и совершенствование системы подготовки кадров. В 2024 году с учетом новых вызовов была скорректирована Национальная стратегия развития искусственного интеллекта [1], где, в частности, отмечались нехватка вычислительных мощностей, недостаточное развитие отечественных решений в области искусственного интеллекта, дефицит высококвалифицированных специалистов и инновационных разработок в области ИИ. Кроме того, был намечен ряд целевых показателей, включая увеличение к 2030 количества выпускников вузов с образованием в сфере ИИ с 3 тыс. (2022) до 15,5 тыс. человек в год. Решение такой масштабной задачи потребовало пересмотра портфеля основных образовательных программ (ООП) высшего образования и разработки новых концепций и форматов обучения в области ИИ. Вместе с этим в 2022 году был утвержден новый ФГОС среднего общего образования, в который вошли прerreквизитные для основ ИИ разделы математики и информатики (теория вероятностей, вычисления на графах, программирование на Python, методы и средства искусственного интеллекта и др.). Это создало возможности для реализации сквозной непрерывной структуры обучения в области ИИ, напрямую соединив школу и университеты. За прошедшие 5 лет в РФ открыто более 100 ООП высшего образования в области ИИ [1], запущены крупные образовательные проекты, объединяющие ведущие университеты и индустрию, например, партнерство Сбера и Яндекса в рамках программы AI360 и ведущих математических центров России, коллаборации ООП бакалавриатов, прошедших отбор по конкурсу Минцифры на уровень ДС («Data Science») и ТОП ДС («Top Data Science»). В 2022 году стартовал первый в СПбГУ бакалавриат в об-

ласти математического искусственного интеллекта «Прикладная математика, программирование и искусственный интеллект», ставший в течение двух приемных кампаний 2023 и 2024 годов наиболее востребованной среди всех образовательных программ СПбГУ и программ направления 01.03.02 «Прикладная математика и информатика» других вузов Санкт-Петербурга [6,7]. В этой программе существенный объем составляют дисциплины по фундаментальной и прикладной математике, на которые опираются новые курсы по ИИ, включающиеся в учебный план на третьем году обучения. При реализации этой успешной программы проявились трудности, связанные со сжатыми сроками (4 года) обучения в бакалавриате. Несмотря на обширность фундаментальной математической подготовки для внедрения этих компетенций в глубокое освоение студентами дисциплин по ИИ не хватало существующего периода обучения. Возникшие трудности стимулировали наш интерес к опыту других ООП в РФ в области ИИ. В то же время в соответствии с современными условиями произошли изменения на рынке труда и в государственных программах в сфере ИИ, что отражается в постановке качественно иных задач для подготовки ИИ-специалистов новой формации — исследователей и архитекторов новых моделей и прорывных технологий ИИ. Из прикладной области ИИ трансформируется в самостоятельную область науки, и для ее развития чрезвычайно важен системный подход, основанный на связи науки и образования прежде всего в области фундаментальных и прикладных направлений математики, информатики и современного программирования.

Анализ образовательных программ РФ в области ИИ

Разработка новых ООП как уровня бакалавриата, так и специалитета основывается на изучении образовательного рынка, опыта существующих программ, а также ожиданий рынка труда. На первом подготовительном этапе были сформулированы критерии отбора ООП для анализа. Затем был проведен сравнительный анализ базовой обязательной части (ядра) учебных планов ООП выборки

ведущих бакалавриатов по 11 направлениям подготовки в области ИИ в 6 субъектах РФ и первого специалитета в области математики ИИ, разработанного на Матмехе СПбГУ. В анализ были включены ООП образовательно-научно-индустриального партнерства AI360 и ведущих математических центров РФ и объединенные группы ООП бакалавриатов, прошедших в 2025 году конкурсный отбор в Минцифры на уровень ТОП ДС. Количественный анализ фундаментальной математической составляющей содержания ООП по профилю «искусственный интеллект» проводился на открытых данных. Изучены учебные планы отобранных ООП: перечень и количество дисциплин ядра (объем выборки 1500 дисциплин) по категориям (модулям) «Фундаментальная математика», «Прикладная математика», «Теоретическая информатика и программирование», «Искусственный интеллект» и блоки дисциплин по выбору (ДПВ) по ИИ, трудоемкость дисциплин и категорий в зачетных единицах (з.е.) и контактных часах. С помощью качественного анализа оценивался дизайн ООП по структуре и логике последовательности курсов с учетом объема и разнообразия пререквизитных дисциплин математических основ ИИ для продвинутого освоения категории «Искусственный интеллект». Для интерпретации результатов анализа использовались также другие документы ООП (общая характеристика ООП, образовательные стандарты, паспорт ООП, рабочие программы дисциплин). На основе ранее выполненного авторами анализа ФГОС 2022 года среднего общего образования по математике и информатике учитывалась встроенность в структуру учебных планов и рабочие программы дисциплин пререквизитных для ИИ разделов школьной математики и информатики, что позволяет оптимизировать содержание и объем связанных с ИИ дисциплин уже на первом курсе, тем самым освобождая место для продвинутых разделов и тем.

На рис. 1 представлены результаты анализа ООП в области ИИ трех вузов Санкт-Петербурга, которые вошли в ТОП ДС конкурса Минцифры и проект AI360 образовательно-научно-индустриального партнерства со Сбером и Яндексом: СПбГУ (математикомеханический факультет, факультет математики и компьютерных




Рис. 1. Диаграмма сравнения трудоемкости (в з. е.) модулей дисциплин базовой части ООП трех вузов Санкт-Петербурга в области искусственного интеллекта

наук, факультет прикладной математики и процессов управления), Университет ИТМО, Школа информатики, физики и технологий НИУ ВШЭ в Санкт-Петербурге. Проанализированы 11 ООП (10 уровня бакалавриата и 1 специалитет) по 5 направлениям подготовки (табл. 1). Анализ продемонстрировал различия в базовой части учебных планов выбранных ООП по объему математических дисциплин, которые являются пререквизитами для глубокого освоения продвинутых курсов по ИИ. Специалитет ПМСПИИ на Матмехе в СПбГУ (№ 1, табл. 1) имеет преимущества по объему, разнообразию и содержательному наполнению фундаментального ядра, что обеспечивает непрерывность процесса подготовки высококвалифицированных кадров в области ИИ.

Переход от четырехлетнего бакалавриата к пятилетнему специалитету с увеличением непрерывного базового обучения позволяет студентам полностью освоить и сформировать законченное

фундаментальное ядро математических основ ИИ (разделы фундаментальной и прикладной математики, теоретической информатики), пробелы в котором неизбежно возникают при разрывах обучения в связках бакалавриата и магистратуры [8, 9].

Таблица 1

Список ООП вузов Санкт-Петербурга в области ИИ, отобранных для анализа

№	ВУЗ	ООП	Направление подготовки
1	СПбГУ Мат-мех: ПМСПИИ (спец-т)	Прикладная математика, современное программирование и искусственный интеллект	01.05.01 Фундаментальные математика и механика
2	СПбГУ Мат-мех: ИИиНД	Искусственный интеллект и наука о данных	09.03.03 Прикладная информатика
3	СПбГУ МиКН: AI360: ММО	AI360: Математика машинного обучения	02.03.01 Математика и компьютерные науки
4	СПбГУ МиКН: СП	Современное программирование	01.03.02 Прикладная математика и информатика
5	СПбГУ МиКН: НД	Науки о данных	02.03.01 Математика и компьютерные науки
6	СПбГУ ПМ-ПУ: ПМПУИИ	Прикладная математика, процессы управления и искусственный интеллект	01.03.02 Прикладная математика и информатика
7	ИТМО: AI360: ML Native	AI360: ML Native	01.03.02 Прикладная математика и информатика
8	ИТМО: ИИИ	Инженерия искусственного интеллекта	02.03.03. Математическое обеспечение и администрирование информационных систем 11.03.02. Инфокоммуникационные технологии и системы связи
9	ИТМО: КТПИ-ИИ	Компьютерные технологии: Программирование и искусственный интеллект	01.03.02 Прикладная математика и информатика

Окончание табл. 1

10	НИУ ВШЭ СПб: ПМИ	Прикладная математика и информатика	01.03.02 Прикладная математика и информатика
11	НИУ ВШЭ СПб: ПАДИИ	Прикладной анализ данных и искусственный интеллект	01.03.02 Прикладная математика и информатика

Концепция первого специалитета в области математики ИИ

Специалитет «Прикладная математика, современное программирование и искусственный интеллект», разработанный на Математико-механическом факультете СПбГУ, дает фундаментальное образование по чистой и прикладной математике и фокусируется на подготовке специалистов в области математической теории и методов ИИ для научной деятельности и работы в прорывных интеллектуальных отраслях индустрии. Фундаментальность математической подготовки и закладывание теоретических основ программирования осуществляется за три года и обеспечивается платформенной частью учебного плана, включающего существенный объем основополагающих математических дисциплин и базовую информатику, которые служат пререквизитами для теоретических и прикладных курсов в области ИИ. Параллельно с формированием фундамента программы, опираясь на современные стандарты школьного образования по математике и информатике, с первого курса студенты погружаются в изучение математических основ ИИ и современных методов и инструментов программирования, необходимых для эффективного взаимодействия с системами ИИ и их практического применения для работы в индустрии по окончании платформенного периода обучения. Нарращивание квалификации и вариативность образования реализуется через разнообразие образовательных траекторий, начиная с третьего года обучения. Сочетание глубокого погружения в математику ИИ и параллельное использование ИИ в процессе обучения и практической подготовки создаёт продуктивную базу

для углубленного понимания методов и технологий ИИ. Этот подход формирует у будущих выпускников профессиональные компетенции для усовершенствования систем ИИ, генерирования новых концепций его развития и разработки передовых решений в науке и прикладных интеллектуальных областях, связанных с математической теорией и приложениями ИИ. Программа реализуется в образовательно-научно-индустриальном партнерстве с компаниями Сбер, Т-банк, Яндекс и другими. Высокое качество подготовки будущих специалистов верифицируется и настраивается в процессе учебы при участии в преподавании, стажировках, практике и экспертной оценке структуры и наполнения учебного плана и содержания дисциплин индустриальных партнеров и научных центров [9–11].

Актуальность формата и содержания нового специалитета по математике ИИ на Матмехе подтверждена и поддержана внешней экспертизой. В рецензии на пакет документов программы потенциальными работодателями отмечено, что «разработанный на Матмехе СПбГУ специалитет «Прикладная математика, современное программирование и искусственный интеллект» стал первым специалитетом в России, который включает наиболее полный спектр необходимых взаимосвязанных фундаментальных математических основ ИИ, а также учитывает обновленный школьный ФГОС 2022 для непрерывного продолжения обучения ИИ со школьного уровня. Сравнительный анализ учебных планов продвинутых образовательных программ индустриально-университетского партнерства AI360 и ведущих математических центров России показал преимущество нового специалитета на Матмехе СПбГУ по объему и наполнению курсов, необходимых для глубокого понимания моделей ИИ» [9,10].

Заключение

Растущий спрос рынка труда на специалистов в области ИИ для индустрии и других отраслей экономики имеет разнообразные ниши с существенным дефицитом кадров. Учитывая появ-

ление новых мультидисциплинарных профессий, связанных с внедрением ИИ в образование, науку, индустрию, практическое использование и жизнеобеспечение, при подготовке таких кадров помимо освоения необходимых компетенций в области ИИ важно делать акцент на формировании профессиональной роли будущих специалистов в новых, еще неизвестных, условиях развития ИИ. Гибкость мышления, системный подход, логичность и строгость рассуждений, широта кругозора, которые развиваются в рамках непрерывного фундаментального образования с увеличенным базовым периодом (специалитет), дают преимущества для вхождения в элитный кластер профессионалов в области математики ИИ. Специалисты этого сегмента смогут составить теоретическое ядро междисциплинарных команд как в научных, так и прикладных разработках в академических институтах и индустрии. Дальнейшее развитие эти специалисты могут продолжать в рамках аспирантуры и последующей научной работы в области ИИ, в высокотехнологичных компаниях индустрии и наращивать междисциплинарные компетенции в магистратурах по другим направлениям.

Данная работа и пленарный доклад на конференции [12] выполнены при финансовой поддержке Санкт-Петербургского государственного университета (проект 128783603).

Библиография

1. Указ Президента Российской Федерации от 15.02.2024 №124 «О внесении изменений в Указ Президента Российской Федерации от 10 октября 2019 г.»
2. Л. М. Гохберг, Ю. В. Туровец, К. О. Вишневский. Искусственный интеллект в России. Технологии и рынки. — М.: Изд. Дом ВШЭ, 2025, 148 с.
3. Указ Президента РФ от 12.05.2023 №343 «О некоторых вопросах совершенствования системы высшего образования».
4. Приказ Министерства просвещения РФ от 12 августа 2022 г. № 732 «О внесении изменений в федеральный государственный образовательный стандарт среднего общего образования, утвержденный приказом Министерства образования и науки Российской Федерации от 17 мая 2012 г. № 413».

5. Указ Президента РФ от 10.10.2019 № 490 (ред. 15.02.2024) «О развитии искусственного интеллекта в Российской Федерации» (с изменениями, вносимыми в Национальную стратегию, утвержденную этим Указом), 15.02.2024 г. (<http://publication.pravo.gov.ru/document/0001202402150063>).

6. **Н. В. Кузнецов.** «Сквозная система подготовки высококвалифицированных кадров в области кибернетики и искусственного интеллекта на базе фундаментальной математики в СПбГУ», 20.11.2024, Заседание Научного совета по теории и процессам управления РАН (https://vkvideo.ru/video-220669694_456239076).

7. **S. Abramovich, N. Kuznetsov, A. Razov, G. A. Leonov.** Eminent scholar, admired teacher and unconventional administrator. Vol.1864, 2021, art. num. 012066 (<https://dx.doi.org/10.1088/1742-6596/1864/1/012066>).

8. **Н. В. Кузнецов.** Первый в России специалитет в области математики искусственного интеллекта // Фундаментальные проблемы обучения математике, информатике и информатизации образования: сборник тезисов докладов XI Международной научно-практической конференции в рамках международного научно-образовательного форума «Математика. Информатика. Образование», Владикавказский НЦ РАН, РСО-Алания, 29 июня – 05 июля 2025 г. – Елец: ЕГУ им. И. А. Бунина, 2025. С. 69–70 (https://fpmi.elsu.ru/docs/FPMI-2025_Abstracts.pdf#page=66).

9. Выступление Н. В. Кузнецова на ученом совете Математико-механического факультета СПбГУ 17.04.2025. URL https://vkvideo.ru/video-220669694_456239106.

10. Протокол заседания ученого совета Математико-механического факультета СПбГУ от 17.04.2025 (https://spbu.ru/sites/default/files/2025-04/20250417_protokol_us_math.pdf).

11. В СПбГУ запустят первую в стране программу специалитета в области математики ИИ, Новости СПбГУ, 19.08.2025 (https://spbu.ru/news-events/novosti/v-spbgu-zapustyat-pervuyu-v-strane-programmu-specialiteta-v-oblasti-matematiki)).

12. Первый в России специалитет в области математики искусственного интеллекта: наука и индустрия (Матмех СПбГУ). Пленарный доклад Н.В. Кузнецова и др. на Всероссийской научно-практической конференции «Промышленный искусственный интеллект», 3–4 июля 2025, Санкт-Петербургский политехнический университет Петра Великого (https://vk.com/video-220669694_456239121?t=4m40s).

RUSSIA'S FIRST SPECIALIST'S STUDIES IN THE FIELD OF MATHEMATICS OF ARTIFICIAL INTELLIGENCE: SCIENCE AND INDUSTRY

Nikolay V. Kuznetsov^{1, a}, Maxim V. Abramov^{1, 2, b}, Tatyana A. Alexeeva^{1, 3, c}, Mikhail V. Blagov^{1, d}, Elena V. Kudryashova^{5, e}, Ruslan N. Mokaev^{1, f}, Timur N. Mokaev^{1, g}

¹St Petersburg University, ²Sberbank, ³HSE University

^ankuznetsov239@mail.ru, ^bm.abramov@spbu.ru, ^ctalekseeva@hse.ru,

^dm.blagov@spbu.ru, ^ee.kudryashova@spbu.ru,

^fr.mokaev@spbu.ru, ^gt.mokaev@spbu.ru

Abstract. Progress in the development of new models and architectures of artificial intelligence (AI) as a key factor in technological leadership in the field of AI requires training professionals of the excellence cluster in the field of AI mathematics. Analysis of modern educational programs in AI of leading universities of the Russian Federation shows the advantage of a specialist degree for the formation of a complete fundamental core of the mathematical foundations of AI and overcoming the gaps that arise when training is broken in the bachelor's and master's degree tandem.

Keywords. Technological leadership, artificial intelligence, mathematics, computer science, higher education, specialist, Federal State Educational Standard of Secondary Education.

* * *

УДК 681.5

doi:10.18720/SPBPU/2/id25-511

РОССИЙСКАЯ АСУ ТП: ТЕХНОЛОГИЧЕСКИЙ СУВЕРЕНИТЕТ В ПРОМЫШЛЕННОЙ АВТОМАТИЗАЦИИ

Одегов Валерий Евгеньевич

АО «Атомик Софт», г. Томск, Россия

info@atomiq.ru

Аннотация. В статье рассматриваются проблемы и перспективы достижения технологического суверенитета в области промышленной ав-

томатизации России. Анализируются вызовы, связанные с санкционным давлением, зависимостью от зарубежных решений, кадровым дефицитом и устаревшими стандартами. Приводится опыт компании «Атомик Софт» по разработке Альфа платформы, закрывающей уровни АСУ ТП и диспетчеризации.

Ключевые слова. технологический суверенитет, промышленная автоматизация, автоматизированная система управления технологическим процессом (АСУ ТП), диспетчеризация, «Атомик Софт», Альфа платформа, критическая информационная инфраструктура (КИИ), программное обеспечение (ПО).

Технологический суверенитет: актуальность, вызовы, текущая ситуация

С 2014 года появились признаки возможных ограничений в применении программных продуктов и оборудования иностранного производства. Эти признаки не носили выраженного характера, сценарий масштабного введения санкций рассматривался как маловероятный. Легкая доступность лучших мировых продуктов, решений и практик казалась привычной и незыблемой. На государственном уровне задачи по адаптации к санкционному режиму на тот момент явно не формулировалось, однако потенциальная перспектива эскалации санкционного давления, обозначенная отдельными тревожными сигналами, потребовала пересмотра приоритетности внедрения программных и технических решений российского производства. В 2014 году команда разработчиков Альфа платформы окончательно сформулировала для себя задачу по созданию продукта, который мог бы полноценно замещать иностранные решения. С этого момента стартовала работа над первым выпуском Альфа платформы.

В 2022 году санкционный режим усилился и произошел массовый уход иностранных компаний с российского рынка.

По состоянию на сегодня по многим отраслевым контурам, включая технологическое управление в промышленности, практически отсутствуют отечественные разработки, способные полноценно заменить привычные иностранные решения. На текущий момент в непрерывных процессах в АСУ ТП технологический

суверенитет обеспечен. Однако решения класса распределенных систем управления (DCS) российской разработки, сопоставимые по функциональности с такими мировыми лидерами, как DeltaV (Emerson), Experion PKS (Honeywell), CENTUM CS 3000 (Yokogawa), по нашему мнению, пока на рынке не представлены. Созданная компанией «Атомик Софт» Альфа платформа, которая закрывает уровни АСУ ТП и диспетчеризации, функционально находится на одном уровне с лучшими иностранными платформами аналогичного класса, такими как System Platform (AVEVA), WinCC OA (SIEMENS), GENESIS (Mitsubishi Electric Iconics Digital Solutions).

Сложность задачи достижения технологического суверенитета в контуре автоматизации промышленного производства (радиоэлектронная промышленность, программные продукты)

За последние четыре десятилетия произошла стагнация российской радиоэлектронной отрасли. Отсутствовали системные инвестиции как в технологии производства чипов или дискретных компонентов, так и в разработку линейки микропроцессоров, модулей аналогового ввода/вывода, аналого-цифровых преобразователей, цифро-аналоговых преобразователей, сигнальных процессоров (DSP) и т. д.

К моменту распада СССР страна обладала конкурентоспособными технологиями в области цифровой и аналоговой электроники. Однако после того, как Советский Союз прекратил свое существование, развитие отрасли фактически замерло. И хотя отдельные разработки и производство компонентов продолжалось в основном для нужд оборонно-промышленного комплекса, в большинстве отраслей предпочтение отдавалось решениям зарубежных (преимущественно американских) производителей. Отечественные разработки процессоров (линейки «Эльбрус», «Байкал»), включая решения с оригинальной архитектурой, велись недостаточно интенсивно. По факту это не позволило сформировать конкурентоспособную альтернативу зарубежным аналогам.

Сложившаяся практика ориентации на иностранные решения создала критическую зависимость, полностью проявившуюся после ужесточения санкций. Текущие ограничения на поставку электронных компонентов (особенно для новых перспективных разработок), с одной стороны, создают существенные трудности, с другой — дают мощный импульс для возрождения индустрии разработки и производства современных элементов компонентной базы, на основе которой можно решать задачи развития российской электроники.

Ситуация с программным обеспечением развивалась по аналогичному сценарию. Проникновение иностранных вендоров на российский рынок сопровождалось планомерным замещением отечественных стандартов, технических решений, оборудования и программного обеспечения их собственными. Несмотря на наличие перспективных разработок, унаследованных со времен СССР и созданных в ранний постсоветский период, их внедрению препятствовали дефицит финансирования и отсутствие рыночного спроса на фоне устойчивого предпочтения западным технологиям.

Высокотехнологичное производство предполагает наличие встроенной автоматизированной системы управления. Иностранные технологические комплексы поставлялись комплектно. Таким образом, встроенные в них АСУ ТП стали де-факто подтвержденными решениями для российских производств. Это привело к резкому сокращению финансирования российских разработчиков, что, в свою очередь, вызвало их постепенную деградацию, закрытие или трансформацию в иные сущности.

Критически устаревшие стандарты времен СССР, определяющие требования к техническим решениям при создании АСУ ТП, фактически заменены иностранными стандартами семейства МЭК. Несмотря на рекомендательный статус, в отсутствие альтернатив, зарубежные стандарты стали де-факто действующими. На них начали ориентироваться проектные институты, заказчики и компании, основным видом деятельности которых является системная интеграция.

На сегодняшний день запрос профессионального сообщества автоматизаторов получил государственный отклик — сформулирована задача по воссозданию системы государственных стандартов. Эта нормативная база станет регуляторным механизмом для создания и развития средств автоматизации промышленности. На текущий момент правовое поле формируют следующие концептуальные документы:

- Федеральный закон от 07.04.2025 № 58-ФЗ «О внесении изменений в Федеральный закон «О безопасности критической информационной инфраструктуры Российской Федерации».

- Указ Президента РФ от 30.03.2022 № 166 «О мерах по обеспечению технологической независимости и безопасности критической информационной инфраструктуры Российской Федерации».

- Указ Президента РФ от 01.05.2022 № 250 «О дополнительных мерах по обеспечению информационной безопасности Российской Федерации».

- Постановление Правительства Российской Федерации от 14.11.2023 № 1912 «О порядке перехода субъектов критической информационной инфраструктуры Российской Федерации на преимущественное применение доверенных программно-аппаратных комплексов на принадлежащих им значимых объектах критической информационной инфраструктуры Российской Федерации».

- Постановление Правительства РФ от 17.07.2015 № 719 «О подтверждении производства российской промышленной продукции».

Переход в режим агрессивной санкционной политики стал для компании «Атомик Софт» не ограничением, а возможностью. Уход иностранных вендоров с рынка освободил нишу, которую компания смогла занять благодаря технологической готовности.

Текущая проблематика обеспечения технологического суверенитета в промышленности

Устойчивый скепсис заказчиков к российским решениям. Технологический нигилизм, основанный на сомнениях в способности отечественных технологических решений соответствовать

требованиям производства, трудно формализуется и имеет, скорее, эмоциональную природу. Преодолеть его можно только через последовательное внедрение систем АСУ ТП на базе российских разработок и подтверждение того, что эти решения полностью покрывают требования производства.

Высокая ресурсоемкость обеспечения технологической суверенности. Разработчикам требуются значительное время и финансовые ресурсы, чтобы довести свои продукты до уровня, обеспечивающего надежную и безаварийную эксплуатацию АСУ ТП. Это касается как программного, так и особенно аппаратного обеспечения, учитывая широту линейки технических средств промышленной электроники: от блоков питания до мощных промышленных коммутаторов, включая контроллеры, модули ввода/вывода, датчики, исполнительные механизмы, приводы, регуляторы и т.д. Государство оказывает значительную финансовую помощь разработчикам через грантовую поддержку.

Дефицит кадров и проблема суверенности образования. Создание работоспособных прототипов технологических решений, их вывод в серийное производство и эксплуатация требуют наличия высококвалифицированных специалистов.

Российская система образования (в первую очередь, высшего) демонстрирует высокий уровень преподавания базовым дисциплинам. Однако до сих пор применяются методики, не способные подготовить специалистов, умеющих работать с современными технологиями. Став образовательным анахронизмом, эти методики перестали быть актуальными.

В свою очередь, иностранные вендоры активно инвестировали в создание учебных лабораторий в российских вузах, полностью оснащая их современным оборудованием и внедряя собственные образовательные методики с привлечением своих специалистов в качестве преподавателей.

Как итог, навыки выпускников ограничены использованием западных технических решений, что усугубляется многолетним оттоком талантливых и перспективных инженерных и научных кадров за рубеж.

Остаточное присутствие иностранных вендоров на рынке. Продукты и решения зарубежного происхождения выдаются за российские, сохраняются каналы поставки оборудования и ПО иностранных вендоров. Отсутствие желания российских предпринимателей применять отечественные решения для особо опасного производства, КИИ и оборонно-промышленного комплекса. Отсутствие комплексной системы государственных стандартов, регламентирующих создание и эксплуатацию промышленных систем, продуктов и технологий. Недостаточный уровень собственных разработок, обусловленный ресурсоемкостью (время, финансирование, кадры). Уровень коммерциализации собственных инновационных разработок в промышленной сфере остается недостаточным.

Четыре сложившиеся позиции эксплуатирующих компаний:

1. Приоритизация проекта по принципу «сначала выбор технологии производства, потом — системы управления», определяющая автоматизацию задач второго порядка.

Как упоминалось ранее, технологические комплексы иностранного производства уже включают встроенные системы управления, что делает их замену предельно сложной. Технологическая установка имеет цикл сопровождения и гарантийные обязательства, и ни один производитель технологического оборудования не сохранит гарантию при замене системы управления на стороннюю. Однако многие установки, эксплуатирующиеся в России в течение многих лет, постепенно достигают этапа замены систем управления в связи с окончанием их жизненного цикла. Это открывает перспективный рынок для отечественных разработчиков как аппаратных, так и программных решений, позволяя замещать иностранные технологии российскими аналогами. Данная задача уже активно решается, и одним из ключевых приоритетов является создание инструментов, обеспечивающих безболезненный переход с иностранных систем на российские.

2. Отсутствие самоопределения компании как субъекта процесса обеспечения технологического суверенитета.

Согласно действующим нормам, предприятия самостоятельно оценивают критичность своего производства и в добровольном порядке решают, относить ли его к объектам КИИ или нет. Если компания заявляет о своей принадлежности к КИИ, то она обязана перейти на российские средства автоматизации, при этом она получает государственные льготы. Если же не заявляет — сохраняет свободу выбора технологий, но лишается государственной поддержки.

Это создает зону неопределенности, однако сам факт наличия такого механизма — положительный момент. Он стимулирует спрос на отечественные решения, обеспечивая российским компаниям уверенность в том, что их продукция будет востребована.

3. Ключевое требование — наличие подтвержденного опыта промышленной эксплуатации предлагаемых решений с демонстрацией релевантных успешных кейсов внедрения.

4. Миф дороговизны российских решений.

Иностранные компании применяли расчетливую стратегию — предлагая комплексные решения, они закладывали основную стоимость в технологическое оборудование, формально предоставляя систему автоматизации «в подарок». Это создавало у заказчиков ложное впечатление о получении выгодного бонуса. Однако на практике затраты на систему управления перераспределялись из капитальных в операционные расходы через механизмы подписок, платной техподдержки и другие, что делало невозможным объективную оценку реальной стоимости.

Российские вендоры сосредоточены на разработке программных продуктов и производстве контроллеров, в отличие от зарубежных концернов, предлагающих комплексное технологическое оборудование. Бизнес-модель основана на прозрачных тарифах и системе льготных условий приобретения, что исключает возможность манипуляций с ценообразованием.

Маркетинг и система технической поддержки как драйверы рыночного потенциала отечественных разработок

Создать качественный продукт — лишь половина успеха. Не менее важно грамотно его презентовать и вывести на рынок. На протяжении долгого времени экспертиза иностранных компаний в части эффективного позиционирования технологий была лидирующей. Уход международных вендоров открыл новые возможности — на рынке появились высококвалифицированные специалисты с опытом работы в международных компаниях. Целенаправленное привлечение таких профессионалов позволяет сделать их экспертизу нашим конкурентным преимуществом. Не менее важна отлаженная техподдержка, которая напрямую влияет на рыночный потенциал продукта. Качественный сервис не только удерживает текущих пользователей, но и является ключевым драйвером повторных продаж и расширения клиентской базы через положительные референсы.

Оптимальная модель вывода продукта на рынок — разработка под конкретного заказчика. Так сокращается время между созданием продукта и его выходом на рынок. Идеальная ситуация складывается, когда такой клиент не просто готов ожидать готовности решения, но и выступать в роли инвестора, обеспечивая финансирование проекта. Это позволяет уже в процессе разработки начинать пилотные внедрения и пробные реализации. Таким образом, к моменту официального релиза у компании уже есть проверенное решение и опыт его использования. Отчасти такая модель использовалась при разработке Альфа платформы: у нас имелись реальные требования заинтересованного в продукте заказчика и его готовность к пилотным проектам на его объектах.

Кадры решают все. Вклад «Атомик Софт» в комплексную систему подготовки кадров на базе вузов

Совместная работа индустрии и университетов представляет особую ценность как для разработки новых технологий, так и для

формирования компетенций и подготовки специалистов, способных работать с современными технологиями и продуктами.

С 2017 года мы запустили собственную корпоративную инициативу, направленную на создание условий для профессиональной подготовки специалистов. Наше сотрудничество с вузами выходит за рамки простого запроса на специалистов — мы заключаем комплексные партнерские соглашения, позволяющие решать сразу несколько важных задач. Главная из них — создание устойчивой системы подготовки кадров, которая отвечает интересам как университетов, так и рынка в целом, включая нашу компанию.

В рамках этого сотрудничества мы открыли исследовательские лаборатории и учебные центры в ведущих вузах страны: ТПУ, СПбПУ, СибГИУ и ОмГТУ. Университеты получают от нас бесплатные лицензии программного обеспечения, методические материалы и доступ к нашим образовательным программам. Это взаимовыгодное партнерство — вузы включают в учебные курсы актуальные практико-ориентированные дисциплины, а мы получаем возможность участвовать в формировании профессиональных компетенций студентов.

Главное преимущество этой системы — возможность совместно разрабатывать учебные курсы и программы. Такой подход обеспечивает инжиниринговым компаниям и заказчикам постоянный приток специалистов, которых целенаправленно обучают работать с современными российскими техническими решениями.

Технологический суверенитет Альфа платформы и востребованность на российском рынке как демонстрация потенциала отечественных решений

Для компании «Атомик Софт», как для российского вендора ПО, технологическая суверенность — это способность разрабатывать и поддерживать свои программные продукты, минимально завися от иностранных технологий, лицензий и инфраструктуры.

С самого начала работы над нашим продуктом мы приняли несколько стратегических решений, которые позже стали основой

технологического суверенитета. В первую очередь — нацеленность на разработку полноценно кросс-платформенного продукта. На старте разработки мы поставили цель не быть привязанными к ОС Microsoft и выйти на работу под управлением ОС Linux. Помимо этого, был сформулирован принцип не использовать в Альфа платформе сторонние коммерческие программные компоненты или готовые проприетарные решения.

Что касается open source (открытого программного обеспечения) — то мы используем ограниченное количество библиотек, характерных для нашего стека технологий. Но только те, которые позволяют нам обеспечить лицензионную чистоту. Мы вели разработку платформы самостоятельно с нуля, применяя только общедоступные инструменты разработки. Архитектура Альфа платформы оригинальна, а весь исходный код находится в нашем распоряжении.

Для компании «Атомик Софт» технологическая суверенность означает не только владение своими технологиями, но и четкое понимание потребностей и требований российских заказчиков. Происхождение компании из крупного системного интегратора обеспечило нам это стратегическое преимущество. Это позволило точно определять требования к продукту и в итоге создать конкурентоспособное ПО, действительно востребованное на рынке.

Библиография

1. Федеральный закон от 07.04.2025 № 58-ФЗ «О внесении изменений в Федеральный закон «О безопасности критической информационной инфраструктуры Российской Федерации» // СПС КонсультантПлюс.
2. Указ Президента РФ от 30.03.2022 № 166 «О мерах по обеспечению технологической независимости и безопасности критической информационной инфраструктуры Российской Федерации» // СПС КонсультантПлюс.
3. Указ Президента РФ от 01.05.2022 № 250 «О дополнительных мерах по обеспечению информационной безопасности Российской Федерации» // СПС КонсультантПлюс.
4. Постановление Правительства Российской Федерации от 14.11.2023 № 1912 «О порядке перехода субъектов критической информационной

инфраструктуры Российской Федерации на преимущественное применение доверенных программно-аппаратных комплексов на принадлежащих им значимых объектах критической информационной инфраструктуры Российской Федерации» // СПС КонсультантПлюс.

5. Постановление Правительства РФ от 17.07.2015 № 719 «О подтверждении производства российской промышленной продукции» // СПС КонсультантПлюс.

RUSSIAN AUTOMATION AND PROCESS CONTROL SYSTEMS: TECHNOLOGICAL SOVEREIGNTY IN INDUSTRIAL AUTOMATION

Valery E. Odegov

JSC Automiq Software, Tomsk, Russia

info@automiq.ru

Abstract. The paper explores the challenges and prospects of attaining technological sovereignty in the industrial automation of Russia. It provides a comprehensive analysis of constraints stemming from sanctions, dependence on foreign technologies, shortage of qualified specialists, and obsolete technical standards. Particular attention is given to the success case of Automiq Software and development of Alpha Platform software, which covers the levels of supervisory control and data acquisition (SCADA) and process control systems.

Keywords. Technological sovereignty, industrial automation, process control and monitoring systems, Automiq Software, Alpha Platform, critical information infrastructure (CII), software.

* * *

Секция 1.

ПРОГРАММНО-АППАРАТНЫЕ ПЛАТФОРМЫ И ТЕХНОЛОГИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СИСТЕМАХ АВТОМАТИЗАЦИИ И УПРАВЛЕНИЯ

УДК 519.673

doi:10.18720/SPBPU/2/id25-512

ГИБРИДНЫЕ ФИЗИКО-ОСВЕДОМЛЕННЫЕ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ И НЕЙРОСИМВОЛЬНЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ – ОСНОВА ЦИФРОВЫХ ДВОЙНИКОВ ТРУБОПРОВОДНЫХ СИСТЕМ ЭНЕРГЕТИКИ

Белинский Александр Вячеславович

ООО «НИИгазэкономика», г. Санкт-Петербург, Россия

A.Belinsky@econom.gazprom.ru

Аннотация. В статье рассмотрены подходы к разработке математического обеспечения цифровых двойников больших структурно-сложных трубопроводных систем (ТПС) энергетики: газо-, тепло-, водо-, нефтехимического и др. Обсуждается два класса задач – моделирование динамики функционирования и концептуальный инжиниринг ТПС. Для их решения предложено использовать парадигмы дифференцируемого и декларативного программирования, гибридные модели и технологии нейросимвольного искусственного интеллекта. Результаты вычислительных экспериментов демонстрируют адекватность моделей и высокую производительность алгоритмов.

Ключевые слова. трубопроводная система, цифровой двойник, нейросимвольный искусственный интеллект.

Введение

Среди множества цифровых решений, которые внедряются в энергетических компаниях, особое внимание уделяется цифровым двойникам (ЦД) активов и технологических процессов. Считается, что ЦД имеют весомый потенциал для совершенствования управления производством [1].

Концепция цифрового двойника была впервые предложена Майклом Гривзом в 2002 г. в рамках работ по управлению жизненным циклом продуктов [2]. Автор рассматривает цифровой двойник как виртуальное представление физического продукта на всех этапах его существования – от проектирования и производства до эксплуатации и утилизации. В этой концепции физический объект или система связаны с их цифровыми моделями (виртуальными копиями) двунаправленными связями, по которым в реальном времени осуществляется обмен потоками данных. Такая архитектура позволяет тестировать изменения в виртуальной среде перед внедрением в реальный мир.

В российском стандарте [3] указано, что ЦД – это система, состоящая из цифровой модели изделия и двусторонних информационных связей с изделием (при наличии изделия) и (или) его составными частями. Под цифровой моделью понимается система математических и компьютерных моделей, а также электронных документов, описывающая структуру, функциональность и поведение вновь разрабатываемого или эксплуатируемого изделия на различных стадиях жизненного цикла.

Авторы работы [4] предлагают классификацию целей применения ЦД: 1) прогнозирование состояния системы на основе текущих и ретроспективных данных; 2) имитационное моделирование поведения системы для тестирования сценариев «что если?»; 3) интероперабельность активов – оптимизированная интеграция активов в сложных системах; 4) помощь при техническом обслуживании, включая прогнозирование неисправностей или отказов оборудования; 5) визуализация текущего состояния или поведения системы; 6) имитация результата и моделирование будущего

поведения системы (например, в концептуальном инжиниринге для генерации и тестирования вариантов конструкции системы).

Применительно к ТПС, в работе [5] под ЦД предлагается понимать компьютерную модель, способную замещать реальный объект в процессах анализа и прогнозирования последствий принятия решений. Среди совокупности математических моделей, которыми должен быть оснащен ЦД, центральное место отводится модели динамики режимов (состояния) ТПС. Такая модель рассматривается автором как составная часть ТПС на пути их трансформации в киберфизические системы.

Вместе с тем, в ряде работ, посвященных компьютерному моделированию ТПС [6, 7 и др.], отмечается высокая вычислительная сложность задач динамических расчетов режимов. В случае больших структурно-сложных ТПС это обстоятельство сдерживает внедрение ЦД на практике.

Моделирование динамики функционирования ТПС

В качестве мотивационного примера рассмотрим Единую систему газоснабжения России (ЕСГ) – крупнейшую в мире ТПС, в структуру которой входит более 180 тыс. км магистральных газопроводов, сотни тысяч объектов запорной арматуры, несколько тысяч газораспределительных станций.

Динамика течения газа в длинных газопроводах хорошо описывается системой дифференциальных уравнений в частных производных, которые вытекают из законов сохранения массы, импульса и энергии [6, 7]:

$$\frac{\partial p^2}{\partial x} = -\Lambda q |q|; \quad \frac{\partial p}{\partial t} = -B \frac{\partial q}{\partial x}, \quad (1)$$

где функции $p(x, t)$, $q(x, t)$ – средние по сечению трубы, перпендикулярному оси трубопровода, значения давления и коммерческого расхода газа; Λ , B – коэффициенты, зависящие от характеристик труб, свойств газа и единиц измерения; x – пространственная координата; t – временная координата.

Традиционный подход к моделированию ТПС предусматривает численное решение системы (1). Для того, чтобы она имела однозначное решение, требуется задать начальные и граничные условия. В качестве начальных условий зачастую принимают стационарный режим течения, а в качестве граничных задают две из четырех функций $p(x, t)$, $q(x, t)$ [7]. Систему уравнений дополняют моделями физико-химических свойств (ФХС) газа и газового потока, уравнениями баланса газа, а также моделями других технологических объектов технологической схемы (силового оборудования, местных сопротивлений и др.). Например, расчет режима работы крана зачастую выполняется на основе решения системы уравнений, состоящих из уравнения потерь давления на сопротивление и уравнения энергии [6]:

$$\Delta p = p_{\text{вх}} - p_{\text{вых}} = \zeta \frac{\rho_c^2 R}{2 F_{\text{вых}}^2} \frac{T_{\text{вых}} z_{\text{вых}}}{p_{\text{вых}}} \cdot Q_{\text{вх}}^2, \quad (2)$$

$$T_{\text{вых}} = T_{\text{вх}} - D_i(p_{\text{вх}} - p_{\text{вых}}),$$

где $p_{\text{вх}}$, $p_{\text{вых}}$, $T_{\text{вх}}$, $T_{\text{вых}}$ — значения давления и температуры газа на входе и выходе крана соответственно; D_i — среднее значение коэффициента Джоуля-Томсона; $z_{\text{вых}}$ — значение коэффициента сжимаемости на выходе крана; $F_{\text{вых}}$ — площадь сечения трубы за краном; ρ_c — плотность газа при стандартных условиях; ζ — коэффициент гидравлического сопротивления; $Q_{\text{вх}}$ — расход газа через кран.

Численное моделирование динамики функционирования газотранспортной системы (ГТС) ЕСГ предусматривает пространственно-временной расчет значений давления, температуры и свойств газа в каждом узле расчетной сетки, а также расходов газа через все объекты. Имитационная модель в дискретной форме может быть записана в общем виде:

$$\mathbf{x}_{j+1} = \mathbf{F}_j(\mathbf{x}_j, \mathbf{u}_j, \boldsymbol{\theta}, \Delta t), \quad j = 0, \dots, N-1$$

$$\mathbf{x}(0) = \mathbf{x}_0, \quad (3)$$

где $\mathbf{F}$ — модель динамики состояния системы; $\mathbf{x}$ — вектор фазовых координат; $\mathbf{u}$ — вектор управляющих воздействий; $\boldsymbol{\theta}$ — параметры

модели; j — номер временного шага; N — число временных шагов; Δt — дискретизация по времени.

Модель (3) составляет основу математического аппарата для решения ранее отмеченных задач ЦД. Вместе с тем, высокая вычислительная сложность соответствующих алгоритмов требует поиска способов ускорения вычислений. Перспективным направлением решения этой проблемы является использование различных аппроксимаций моделей элементов ТПС. К указанным аппроксимационным моделям предъявляются требования приемлемой точности и высокой скорости расчетов.

Физико-осведомленные модели машинного обучения ТПС

Аппроксимация моделей объектов ТПС. Рассмотрим модель (2). При известных параметрах газа и газового потока на входе в кран можно рассчитать параметры газового потока на его выходе. Обычно расчет выполняется одним из численных методов, например, методом прямой итерации. Использование итерационных алгоритмов при расчетах больших ТПС сопряжено с высокими вычислительными затратами.

Не отказываясь от модели (2) как эталонной, рассмотрим ее аппроксимацию, т. е. перейдем от физической модели к ее суррогатной версии (которую также можно именовать прокси-моделью [8]). Построим параметрическую зависимость вида $Q_{\text{вх}} = f_{\theta}(p_{\text{вх}}, p_{\text{вых}}, T_{\text{вх}}, \delta)$, где δ — степень открытия крана, а функцию $f_{\theta} : R^{d_x} \rightarrow R^{d_y}$ (d_x, d_y — размерности входного и выходного пространств) с параметрами $\theta \in \Theta$ выберем из семейства искусственных нейронных сетей (ИНС) прямого распространения. Для обучения ИНС следует подготовить выборку $\{\mathbf{x}_i, y_i\}$, где $\mathbf{x}_i = (p_{\text{вх}}, p_{\text{вых}}, T_{\text{вх}}, \delta)$, $y_i = Q_{\text{вх},i}$. Обход признакового пространства можно выполнить, например, с помощью метода латинского гиперкуба [8].

Универсальная теорема аппроксимации гарантирует, что ИНС может аппроксимировать исследуемую функцию с любой точностью. Вычислительные эксперименты показывают, что даже относительно неглубокая ИНС обеспечивает высокое качество ап-

проксимации рассматриваемой физической модели. Так, на рис. 1 приведена поверхность, отражающая зависимость между $Q_{\text{вх}}$ и $p_{\text{вых}}$, δ (при фиксированном $p_{\text{вх}}$, $T_{\text{вх}}$). Поверхность построена с помощью обученной ИНС из трех внутренних слоев по 64 нейрона в каждом, а точками обозначены значения, полученные по модели (2). Видно, что $y_j \approx f_0(x_j)$. Значения метрик качества подтверждает это наблюдение во всем рассмотренном пространстве данных. Это делает возможным применение функции f_0 в качестве замыкающего соотношения при расчете потокораспределения в ТПС.

Важной особенностью прокси-модели является ее высокая вычислительная производительность. Расчет крана с помощью ИНС осуществляется на 1–2 порядка быстрее по сравнению с эталонной моделью (2).

Аналогичные подходы можно применить для составления прокси-моделей других «точечных» объектов ТПС, в расчетах которых можно пренебречь изменением параметров потока газа по линейной координате. Однако для линейно протяженных трубопроводов следует использовать иные подходы к составлению

Аппроксимация модели крана




Рис. 1. Нейросетевая физико-осведомленная модель крана-регулятора

прокси-моделей. Методы машинного обучения предлагают решения, которые способны значительно ускорить процесс моделирования таких объектов, сохраняя при этом приемлемую точность.

Физико-информированные нейронные сети. Физико-информированные нейронные сети (англ. Physics-Informed Neural Networks, PINN) получили широкое распространение благодаря работе [9]. Суть метода заключается в том, что на вход в PINN подается значение линейной координаты x и времени t , а также различные константы, описывающие конструкцию трубопровода. На выходах PINN моделируются интересные физические параметры, например, потенциал, расход, температура газа. Автодифференцируемость PINN позволяет эффективно вычислить частные производные этих параметров по t и x . Подставив значения параметров и их частных производных в систему дифференциальных уравнений, описывающих режим течения флюида в трубопроводе (например, в систему (1)), можно получить значения невязок уравнений. Добавив к ним невязки, характеризующие отклонения от заданных граничных и начальных условий, можно сформировать функцию потерь, минимизация которой фактически тождественна решению соответствующей краевой задачи для системы (1).

На рис. 2 приведены результаты сравнения расчетного давления газа в разных точках газопровода, полученные с помощью PINN и численного метода. Исследование значений метрик качества показывает, что предсказание такой прокси-модели осуществляется с высокой точностью. При этом скорость прогноза с помощью заранее обученной PINN на 2 порядка выше, чем при использовании численного метода.

Несмотря на привлекательность идеи PINN, использование таких прокси-моделей при моделировании ТПС сопряжено с необходимостью переобучения нейронных сетей при изменении краевых условий. Очевидно, что для реальных ТПС, включающих сотни и тысячи трубопроводов, использование PINN неэффективно. Тем не менее, для решения отдельных задач ЦД (например, имитационного моделирования отдельных трубопроводов), PINN может служить действенным инструментом для проведения исследований.




Рис. 2. Сравнение расчетного давления газа в разных точках газопровода, полученные с помощью PINN и численного метода

Нейронные операторы. Нейронные операторы относят к классу методов машинного обучения, которые обучаются на больших объемах данных и на их основе изучают решения семейства дифференциальных уравнений. Одним из таких методов является метод с применением нейронного оператора Фурье (ФНО), который использует спектральные представления данных для быстрого и точного моделирования динамических процессов. Обученный нейронный оператор может на порядки быстрее выдавать решение, чем при использовании традиционных подходов. Такая модель также позволяет получить желаемую инвариантность от точности дискретизации координатной сетки при использовании обученной модели. Одно из главных преимуществ ФНО состоит в том, что обучить его потребуется только один раз – решения для нового набора исходных данных получаются путем прямого прохода через нейронную сеть, прямым расчетом без численного решения каких-либо уравнений.

В работе [10] предложен метод моделирования нестационарных режимов работы газопроводов с помощью ФНО и представлены

результаты численного эксперимента. Полученные в ходе эксперимента метрики подтвердили хорошее приближение результатов моделирования к исходным численным решениям уравнений газовой динамики. Пример результатов моделирования динамики изменения давления газа с применением ФНО приведен на рис. 3.




Рис. 3. 2D-отображение предсказания изменения давления газа в трубопроводе: а – протяженностью 100 км, диаметром 1420 мм; б – протяженностью 60 км, диаметром 1020 мм

Исследование значений различных численных метрик качества такой модели демонстрирует приемлемую для практики точность расчетов на ее основе. При этом такая обученная модель обладает вычислительной производительностью, на 3–4 порядка превышающей традиционные численные методы, а также инвариантна к изменению степени дискретизации пространственно-временной сетки [10].

Гибридные модели крупных ТПС. Вернемся к рассмотрению задачи моделирования динамики функционирования ТПС и мотивационному примеру. Моделирование технологических режимов работы подобных крупных ТПС до недавнего времени оставалось нерешенной задачей ввиду ее высочайшей размерности и вычислительной сложности. Однако в работах [11, 12, 13] предложены новые подходы к решению задач имитационного моделирования и поиска квазиоптимальных режимов работы ТПС на основе гибридных моделей.

Основная идея гибридной модели ТПС состоит в объединении моделей ее элементов, которые могут быть построены на основе различных принципов. Например, в такой модели краны-регуляторы могут быть представлены нейросетевой прокси-моделью, пример которой приведен на **рисунке 1**. Отдельные трубопроводы могут быть представлены моделью дифференциальных уравнений типа (1). Иные газопроводы, для которых допустима небольшая погрешность моделирования в угоду высокой скорости счета, могут быть представлены с помощью нейронных операторов. В целом, рациональная комбинация моделей может подбираться в зависимости от вида решаемой задачи ЦД, требований к точности результатов моделирования, наличия исходных данных. Комбинированная модель, построенная в парадигме ДП, сохраняет свойства автодифференцированности и аппаратного ускорения вычислений на графических процессорах. Это, в свою очередь, открывает новые возможности для решения ранее отмеченных задач ЦД.

Эксперимент, проведенный в работе [13], позволил убедиться в возможности создания гибридных моделей для реальных крупных

ТПС. Ключевым результатом создания такой модели, важным для практики, является высокая вычислительная производительность соответствующих алгоритмов. Так, в работах [11, 13] показано, что прирост скорости вычислений может составлять несколько порядков по отношению к традиционным численным методам решения.

Таким образом, гибридные модели ТПС могут служить основой для вычислительных алгоритмов ЦД, предусматривающих моделирование динамики функционирования ТПС.

Нейросимвольный искусственный интеллект в задачах концептуального инжиниринга ТПС

Принципиально иные сложности возникают в задачах концептуального инжиниринга развивающихся ТПС. Целью их решения является обоснование рациональных схемно-структурных вариантов развития ТПС для удовлетворения спроса потребителей на транспортируемую продукцию (газ, нефть и т.д.). В таких задачах обычно возникает естественная потребность в проведении цепочки логических рассуждений, нацеленных на выбор рациональных технических решений по развитию ТПС при наличии различных технико-экономических ограничений. Описанные в работе нейронные сети не в состоянии решать задачи логического вывода.

Рассмотрим задачу концептуального инжиниринга фрагмента ГТС ЕСГ с целью увеличения объемов транспортируемого газа свыше его проектной производительности. Решение задачи предусматривает рациональный выбор технических решений по расширению производственных мощностей фрагмента. Существует множество альтернативных вариантов решения этой задачи, например, за счет реализации следующих технических мероприятий:

- замена труб в любом линейном участке с изменением диаметра;
- замена агрегатов в компрессорных станциях с изменением мощности;
- прокладка дополнительных трубопроводов (лупингов);
- прокладка параллельного трубопровода и др.

Несмотря на возможность реализации любого из вариантов, проектные организации придерживаются ряда правил, доказавших эффективность на практике. Эти правила могут быть формализованы языком логики.

Основная идея предлагаемого подхода к алгоритмизации задач концептуального инжиниринга ТПС заключается в использовании технологий нейросимвольного ИИ, объединяющего символические методы, такие как ASP (Answer Set Programming, программирование ответных множеств), с нейросетевыми моделями ТПС.

ASP [14] — это декларативный метод программирования, основанный на неклассической логике. В ASP задаются правила, а решатель находит непротиворечивые множества решений. Для связи символического и нейросетевого аппарата используются предикаты, например:

$$:- Q < Q_r, Q = \text{произв_мощн}(\text{фрагмент_ГТС}, M), \\ \text{мероприятие}(M). \quad (4)$$

$$\# \text{minimize} \{C : \text{стоимость}(C, M), \text{мероприятие}(M)\}.$$

где произв_мощн — предикат, значение которого (производственная мощность фрагмента ГТС при реализации мероприятия M) вычисляется нейронной сетью, имитирующей работу ГТС; мероприятие — факты (множество мероприятий); знак « $:-$ » означает ограничение, которое исключает недопустимое решение $Q < Q_r$; Q_r — требуемый объем транспортировки газа по фрагменту ГТС; $\text{стоимость}(C, M)$ — факты, содержащие значения стоимости мероприятий.

Очевидно, что целью программы ASP, представленной в формуле (4), является поиск самых дешевых вариантов расширения производственной мощности фрагмента ГТС при условии обеспечения необходимого объема транспортировки газа. Ключевой особенностью этого алгоритма является сочетание логических правил и оценок влияния рассматриваемых мероприятий на производственную мощность, которые вычисляются с помощью физико-осведомленных нейросетевых моделей ТПС.

Результаты вычислительных экспериментов, проведенные на примерах концептуального инжиниринга различных реальных фрагментов ГТС ЕСГ, демонстрируют высокую вычислительную производительность, на несколько порядков превосходя время экспертного поиска. Полученные результаты свидетельствуют об актуальности развития нейросимвольных алгоритмов и необходимости их интеграции в математическое ядро ЦД ТПС.

Заключение

Нейросетевой математический аппарат и технологии нейросимвольного искусственного интеллекта предоставляют методологическую основу для развития ЦД больших структурно-сложных ТПС энергетики. Результаты вычислительных экспериментов демонстрируют, что гибридные модели ТПС, реализованные в современной парадигме дифференцируемого программирования, обладают высокой вычислительной производительностью. Объединение этих моделей и символических методов, таких как ASP, позволяют эффективно решать задачи, требующие логических размышлений.

Для раскрытия потенциала этих интеллектуальных технологий потребуются затраты ресурсов и времени на реимплементацию существующих программно-вычислительных комплексов моделирования и оптимизации ТПС. Однако преодоление этих сложностей откроет новые возможности для развития ЦД и повышения эффективности управления ТПС энергетики.

Библиография

1. Цифровые двойники в высокотехнологичной промышленности: монография / Под ред. А. И. Боровкова. — СПб. : ПОЛИТЕХ-ПРЕСС, 2022. — 492 с.
2. **Grieves, M.** Product Lifecycle Management: Driving the Next Generation of Lean Thinking. 2002.
3. ГОСТ Р 57700.37-2021. Компьютерные модели и моделирование. Цифровые двойники изделий. Общие положения. — Введ. 2022-01-01. — М.: Российский ин-т стандартизации. 2021.

4. **Hasan M.** Decoding Digital Twins: Exploring the 6 main applications and their benefits: Report IoT Analytics. — 2023.

5. **Новицкий Н. Н.** Цифровые двойники трубопроводных систем: назначение, структура, задачи и методические подходы к реализации // Автоматизация и информатизация ТЭК. — 2025. — № 4(621). — С. 62–70.

6. **Сарданашвили С. А.** Расчетные методы и алгоритмы (трубопроводный транспорт газа). — М.: ФГУП Изд-во «Нефть и газ» РГУ нефти и газа им. И. М. Губкина, 2005. — 577 с.

7. **Сухарев М. Г., Самойлов Р. В.** Анализ и управление стационарными и нестационарными режимами транспорта газа. — М.: РГУ нефти и газа (НИУ) им. И.М. Губкина, 2017. — 399 с.

8. **Белинский А. В., Маришкин В. А., Самсонова В. В., Пятибратов П. В.** Разработка и апробация методических подходов и цифровых технологий нейросетевого прокси-моделирования установившегося двухфазного течения многокомпонентной смеси в системах сбора и промышленной подготовки газа (на примере Чаяндинского НГКМ) // Автоматизация и информатизация ТЭК, № 4 (609), 2024.

9. **Raissi, Maziar; Perdikaris, Paris; Karniadakis, George Em** (2017-11-28). «Physics Informed Deep Learning (Part I): Data-driven Solutions of Nonlinear Partial Differential Equations». arXiv:1711.10561 [cs. AI].

10. **Белинский А. В., Горлов Д. В., Пятишев И. А., Титов А. Е.** О новом методе цифрового моделирования нестационарных режимов течения газа в магистральных газопроводах с применением нейронных операторов // Газовая промышленность. — 2024. — № 5(865).

11. **Белинский А. В.** Дифференцируемая физика — основа цифровых двойников в нефтегазовом комплексе // Автоматизация и информатизация ТЭК. — 2024. — № 12(617). — С. 38–50.

12. **Белинский А. В.** Имитационная нестационарная гибридная модель крупной газотранспортной системы с аппаратным ускорением вычислений на графических процессорах // Автоматизация и информатизация ТЭК. 2025. — № 2(619). — с. 34–47.

13. **Белинский А. В.** Планирование нестационарных режимов работы крупных газотранспортных систем с применением итерационного линейно-квадратичного регулятора и методов дифференцируемой физики // Автоматизация и информатизация ТЭК. — 2025. — № 4(621). — С. 20–31.

14. **Tran S. C.** et al. Answer set planning: a survey // Theory and Practice of Logic Programming. — 2023. — Т. 23. — №. 1. — С. 226-298.

HYBRID PHYSICS-AWARE MACHINE LEARNING MODELS AND NEUROSymbolic AI — THE CORE OF DIGITAL TWINS OF PIPELINE SYSTEMS IN ENERGY SECTOR

Alexander V. Belinsky

JSC «NIIgazeconomika», Saint Petersburg, Russia

A.Belinsky@econom.gazprom.ru

Abstract. The article discusses approaches to the development of mathematical methods for digital twins of large-scale structurally complex pipeline systems (TPS) of energy: gas, heat, water, oil supply, etc. Two classes of tasks are discussed — modeling the transient dynamics of functioning and conceptual engineering of TPS. To solve them, it is proposed to use the paradigm of differentiable and declarative programming, hybrid models and technologies of neuro-symbolic artificial intelligence. The results of computational experiments demonstrate the adequacy of the models and the high performance of the algorithms.

Keywords. Pipeline system, digital twin, neuro-symbolic artificial intelligence.

* * *

УДК 622.7.014.4:004.8

doi:10.18720/SPBPU/2/id25-513

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА УПРАВЛЕНИЯ «РАЗУМ»: СКВОЗНОЕ УПРАВЛЕНИЕ ТЕХНОЛОГИЧЕСКОЙ ЦЕПОЧКОЙ ПО ПРОИЗВОДСТВУ ЖЕЛЕЗОРУДНОГО ОКАТЫША

Ануфриев Александр Сергеевич¹, Замятин Алексей Игоревич²

ООО «Лаборатория инжиниринга», Санкт-Петербург, Россия

¹aas@pesk.spb.ru, ²zai@pesk.spb.ru

Аннотация. Статья посвящена разработке интеллектуальной системы управления, обеспечивающей сквозное регулирование процессов добычи и переработки рудного сырья. Актуальность связана с отсутствием согласованного управления между стадиями и низкой адаптивностью существующих решений. Предложена универсальная архитектура на основе цифровых двойников и предиктивного анализа. На примере промышленного внедрения в производство железорудного окатыша показано улуч-

шение технико-экономических показателей и возможность масштабирования решения для других типов горно-обогатительных производств.

Ключевые слова. Интеллектуальное управление, цифровой двойник, добыча полезных ископаемых, переработка руды.

Введение

Процессы добычи и переработки рудного сырья представляют собой многостадийные технологические цепочки с высоким уровнем взаимозависимости между переделами. На практике эти связи редко учитываются в системах управления: каждая стадия функционирует обособленно, что приводит к несогласованности режимов, росту потерь и нестабильности конечного продукта. Проблема несогласованности между стадиями особенно остро проявляется в производстве железорудных окатышей, где технологическая цепочка включает целый ряд этапов рудоподготовки. Нарушения, возникающие на ранних этапах, часто остаются некомпенсированными и приводят к снижению качества конечной продукции [1].

В таких условиях традиционные автоматизированные решения оказываются недостаточными. Требуется интеллектуальный подход, обеспечивающий координацию всех стадий на основе анализа и прогноза поведения сырьевого потока.

Постановка задачи

Описание технологической цепочки производства железорудных окатышей. Комплексный характер технологии получения железорудных окатышей позволяет рассматривать горно-обогатительные предприятия в качестве репрезентативных примеров для выявления типовых проблем межпередельного регулирования.

Один из горно-обогатительных комбинатов России представляет собой предприятие с завершённым технологическим циклом переработки железистых кварцитов, включающим стадии добычи, дробления, измельчения, классификации, обогащения и выпуска товарных окатышей (рис. 1).

Несмотря на наличие современных автоматизированных систем управления на отдельных участках, структура управления на пред-




Рис. 1. Технологическая цепочка производства железорудных окатышей на примере предприятия с завершённым технологическим циклом

приятии сохраняла разрозненный характер, при котором каждый передел работал в рамках собственной логики без полноценного учёта текущих и предсказуемых изменений на смежных этапах [2].

Ключевыми проблемами, выявленными в ходе анализа, стали несогласованность управляющих воздействий между участками, низкая чувствительность к изменениям характеристик сырья, а также запаздывание реакций на нестандартные ситуации в потоке. В результате происходили перегрузки оборудования, нестабильность гранулометрического состава на выходе из мельниц, рост потерь железа в хвостах и снижение выхода кондиционного концентрата. Существующие решения позволяли фиксировать эти отклонения, но не обладали средствами для упреждающего их устранения или адаптации режимов к новым условиям.

Требования к интеллектуальной системе управления. С учётом специфики технологической цепочки производства железорудных окатышей и выявленных ограничений в действующих схемах регулирования, к архитектуре интеллектуальной системы управления предъявляются следующие основные требования:

- Сквозная координация между переделами, обеспечивающая согласование управляющих воздействий с учётом межпеределных зависимостей и динамики состояния сырьевого потока.

- Адаптивность к изменяющимся свойствам сырья, включая гранулометрию, влажность, состав и плотность, с возможностью автоматической корректировки режимов работы оборудования в режиме реального времени.

- Использование прогнозных моделей, позволяющих формировать упреждающие управляющие воздействия на основе анализа тенденций и ожидаемых отклонений.

- Реализация замкнутого контура управления, включающего сбор, интерпретацию и верификацию данных, виртуальное тестирование решений и их последующую реализацию в производственной среде.

- Модульность и интеграция в существующую инфраструктуру, предполагающая совместимость с действующими системами автоматизации (АСУ ТП, MES) и возможность поэтапного внедрения без структурной перестройки управления [3, 4].

Интеллектуальная система управления «РАЗУМ»

Архитектура. Для решения описанных проблем предлагается интеллектуальная система управления (ИСУ) «РАЗУМ», ориентированная на сквозное управление технологической цепочкой переработки сырья. В отличие от традиционных автоматизированных решений, система реализует согласованное регулирование всех стадий — от добычи до выпуска готового продукта — на основе единой цифровой модели потока. В основу системы положены принципы модульности, межпеределной интеграции и замкнутого контура управления.

Представленная на рис. 2 схема отражает принципы интеграции интеллектуальной системы управления «РАЗУМ» в цифровую и автоматизированную инфраструктуру горно-обогатительного предприятия.

Центральным элементом системы является программное обеспечение, выполняющее функции сбора, анализа и оптимизации технологической информации. В программный контур поступают данные от контрольно-измерительных приборов, передаваемые через программируемый логический контроллер (ПЛК), а также информация от MES-системы, агрегирующей оперативные сведения о состоянии производства и лабораторные показатели качества сырья и продуктов переработки. Дополнительно задействован ОРС-сервер, через который система получает доступ к базе параметров, ограничениям и целевым функциям, определяемым на уровне верхней системы управления.

Управляющие воздействия формируются на основе анализа текущего состояния технологического процесса, лабораторных данных и заданных целевых функций. В программной архитектуре реализованы цифровые двойники технологических агрегатов, основанные на математических моделях с периодической эмпирической корректировкой коэффициентов для актуализации моделей. Информация от КИП, ПЛК, MES-системы и лабораторных источников агрегируется в цифровой модели производственного потока, отражающей актуальные характеристики сырья и режимов работы

Таблица 1

Функциональные группы решений ИСУ «РАЗУМ»

№	Группа решений	Назначение	Охват процессов
1	Стабилизация шихты	Снижение потерь при производстве железнорудного концентрата и окатышей за счет увеличения точности информации о поступающей шихтовке руд (обогащаемость, содержание Fe, вес, содержание S)	Управление процессами добычи, транспортировки и подготовки руды.
2	Оптимизация шихты	Формирование задания на постановку шихтовки руд на передел дробления в зависимости от плана по производству концентрата.	Учёт перевозок, контроль гранулометрии, учёт массы материала, расчёт балансов.
3	Повышение эффективности дробления	Обеспечение стабильного гранулометрического состава. Мониторинг и контроль характеристик руды в потоке в режиме реального времени.	Модули «Цифровой поток шихты», «Цифровой бункер». Управление щелевыми зазорами дробилок
4	Повышение эффективности обогащения	Превентивное управление технологическими агрегатами относительно характеристик поступающей руды. Регулирование плотности пульпы и режимов разделения.	Контроль работы мельниц, гидроциклонов, магнитных и магнитно-гравитационных сепараторов, дешламаторов.

Эффективность внедрения и потенциал масштабирования. Эффективность внедрения системы «РАЗУМ» оценивалась на основании анализа динамики технологических и производственных показателей, полученных в ходе промышленной апробации на горно-обогатительном предприятии России. Верификация результатов проводилась путём сопоставления данных, зафиксиро-




Рис. 2. Структурно-функциональная схема интеграции программного обеспечения ИСУ «РАЗУМ» в существующую инфраструктуру предприятия

оборудования. На этой основе многопараметрические регуляторы и алгоритмы предиктивного анализа рассчитывают уставки, обеспечивающие достижение технологических и экономических целевых показателей. Управляющие воздействия передаются в исполнительные контуры через ПЛК, замыкая цикл регулирования. Такая архитектура обеспечивает адаптивное и согласованное управление в реальном времени, учитывающее изменчивость входных условий и взаимосвязи между стадиями переработки [5].

Логическая структура системы «РАЗУМ» основана на совокупности специализированных решений, сгруппированных по функционалу. Каждая группа ориентирована на определённый технологический блок и обеспечивает выполнение задач, соответствующих его роли в общей производственной цепочке (табл. 1).

ванных в стабильных условиях загрузки оборудования, до и после поэтапной интеграции интеллектуальных модулей. Анализ охватывал ключевые участки технологической цепочки, включая дробление, измельчение, классификацию и магнитную дешламацию [6].

Интеграция интеллектуальных модулей позволила повысить производительность секций по перерабатываемой руде в отделении измельчения на 4,21%, увеличить выход концентрата без изменения проектной производительности предприятия на 6,59%. Дополнительным эффектом стало снижение потерь в хвостах и снижение частоты внеплановых остановок оборудования за счёт более точного и упреждающего регулирования (табл. 2).

Работа предприятия под управлением ИСУ «РАЗУМ» на всех переделах позволила отслеживать, с какими характеристиками руда поступает на каждый технологический процесс. За счет этого происходит оперативное изменение режима работы агрегатов и повышается реакция на изменяющиеся параметры в потоке. До внедрения системы при изменении такого параметра руды, как обогатимость, более чем на 5%, без изменения режима работы отделения измельчения, негативно сказывалось в первую очередь на качестве концентрата на выходе. Данное изменение на входе отделения измельчения можно было обнаружить только за счет экспресс анализа лаборатории, который проводится раз в три часа. После интеграции системы данное запаздывание в управлении

агрегатами было исключено. Оперативное управление от ИСУ в том числе исключает перегрузку оборудования, нестабильность гранулометрического состава на выходе из мельниц, а также удерживает в номинальном диапазоне потери железа в хвостах.

Модульная архитектура ИСУ «РАЗУМ», реализующая принципы межпередельной координации, предиктивного анализа и цифрового моделирования, обеспечивает её высокую степень масштабируемости и адаптируемости к различным типам перерабатывающих производств. Универсальность заложенных алгоритмов управления и логики построения цифровых двойников позволяет применять систему в условиях переработки как природного, так и техногенного минерального сырья с вариативными физико-химическими характеристиками.

Промышленная конфигурация системы не привязана к конкретной типологии оборудования или модели технологического передела, что даёт возможность её тиражирования на предприятия с отличающейся структурой технологических цепочек — включая угольные обогатительные фабрики, переработку фосфатных, медно-никелевых, редкоземельных и других комплексных руд. За счёт использования стандартных протоколов обмена (OPC), открытых СУБД и масштабируемой среды исполнения, интеграция в действующую цифровую инфраструктуру возможна без радикального изменения существующих средств автоматизации [7].

Заключение

Проведённый анализ подтвердил, что традиционные системы управления, реализуемые на уровне отдельных переделов, не обеспечивают необходимой согласованности в условиях многозвенной переработки минерального сырья. Отсутствие координации между переделами и низкая чувствительность к изменяющимся свойствам материала приводят к нестабильности технологических режимов и снижению эффективности производства.

Предложенная интеллектуальная система управления «РАЗУМ» реализует концепцию сквозного регулирования за счёт инте-

Таблица 2

Технико-экономические показатели до и после внедрения ИСУ «Разум» на горно-обогатительном комбинате России

Показатель	До внедрения	После внедрения	Эффект
Содержание железа в хвостах, %	2,0	1,47	−0,53
Извлечение железа, %	94,89	97,06	+2,17
Выход товарного продукта, %	31,69	32,42	+0,73

грации цифровых двойников, многопараметрических регуляторов и механизмов предиктивного анализа. Модульная архитектура системы обеспечивает замкнутый контур управления, охватывающий весь производственный цикл от добычи до выпуска готовой продукции. Верифицированные результаты внедрения на промышленной площадке горно-обогатительного комплекса России продемонстрировали устойчивое улучшение технико-экономических показателей, включая рост извлечения железа, снижение потерь в хвостах и увеличение выхода товарного концентрата.

Универсальность архитектурных решений и независимость от конкретных схем оборудования подтверждают возможность масштабирования системы на другие типы горно-обогатительных производств, в том числе на переработку фосфатных, угольных, медно-никелевых и редкоземельных руд.

Библиография

1. Каплунов Д. Р., Рыльников А. Г. Обобщение современных подходов к управлению качеством рудопотоков в условиях действующих рудников // Известия ТулГУ. Технические науки. — 2020. — № 4. — С. 40–53.
2. Кокорев Д. С., Посмаков Н. П. Применение «цифровых двойников» в производственных процессах // Colloquium-journal. — 2019. — № 26(50). — С. 38–45.
3. Матевосян Р. А., Варфоломеев И. А. Интеллектуальный анализ и управление составом агломерационной шихты // Вестник Череповецкого государственного университета. — 2022. — № 6(111). — С. 65–78. — DOI: 10.23859/1994-0637-2022-6-111-65-78.
4. Киселев В. П., Шабанов И. В., Гайнанов А. М. Автоматизация процесса магнитной сепарации на основе адаптивной модели // Вестник ЮУрГУ. Серия: Машиностроение. — 2021. — Т. 21, № 2. — С. 21–28. — DOI: 10.14529/eng210203.
5. Лукичев С. В. Цифровая трансформация и технологическая независимость горнодобывающей промышленности // Горная промышленность. — 2022. — № 5. — С. 74–78.
6. Кантемиров В. Д., Яковлев А. М., Титов Р. С., Тимохин А. В. Совершенствование методов рудоподготовки минерального сырья при освоении сложноструктурных месторождений // Горная промышленность. — 2022. — № S1. — С. 63–70.

7. Хакулов В. А., Кононов О. В., Новиков В. В., Сычев Н. Ф. Проектирование технологии формирования и стабилизации качества руд на основе рудосортировки // Горный информационно-аналитический бюллетень. — 2012. — № 9. — С. 60–62.

INTELLIGENT CONTROL SYSTEM “RAZUM”: END-TO-END CONTROL OF THE TECHNOLOGICAL CHAIN FOR IRON ORE PELLET PRODUCTION

Aleksandr S. Anufriev¹, Aleksey I. Zamyatin²

LLC “Engineering Laboratory”, Saint Petersburg, Russia

¹aas@pesk.spb.ru, ²zai@pesk.spb.ru

Abstract. The article focuses on the development of an intelligent control system that enables end-to-end regulation of mining and mineral processing operations. The relevance of the work stems from the lack of coordinated control between production stages and the low adaptability of existing solutions. A universal architecture based on digital twins and predictive analytics is proposed. An industrial case involving iron ore pellet production demonstrates improved technical and economic performance and the scalability of the solution to other types of mineral processing operations.

Keywords. Intelligent control, digital twin, mineral extraction, ore processing.

* * *

УДК 519.8

doi:10.18720/SPBPU/2/id25-514

МЕТОДОЛОГИЯ И ТЕХНОЛОГИИ АВТОМАТИЗАЦИИ И ИНТЕЛЛЕКТУАЛИЗАЦИИ ПРОАКТИВНОГО УПРАВЛЕНИЯ СЛОЖНЫМИ ОБЪЕКТАМИ

Соколов Борис Владимирович¹, Захаров Валерий Вячеславович

Санкт-Петербургский федеральный исследовательский центр РАН,
Санкт-Петербург, Россия

¹sokolov_boris@inbox.ru

Аннотация. В докладе приведены результаты разработки теоретических основ решения задач многоуровневого многокритериального структурно-функционального синтеза облика заданного сегмента отечественного промышленного интернета вещей (ПриВ), а также сведения о практической реализации данных теоретических основ при разработке технологий проактивного управления многоспутниковой группировкой малоразмерных космических аппаратов, а также при управлении сложными агробиотехническими объектами. Предлагаемая методология и технологии автоматизации и интеллектуализации процессов проактивного управления ПриВ основываются на фундаментальных и прикладных результатах, ранее полученных авторами доклада при выполнении комплексных исследований в рамках междисциплинарной отрасли системных знаний.

Ключевые слова. сложные объекты, проактивное управление, промышленный Интернет вещей, цифровые двойники и цифровые модели, квалиметрия моделей и полимодельных комплексов, жизненный цикл, многоспутниковые группировки, агробиотехнические объекты.

Введение

В настоящее время основные исследования ключевых направлений формирования и эволюции отечественного промышленного интернета вещей (ПриВ) и киберфизических систем (КФС), связаны с разработкой принципиально новых технологий компьютерных вычислений, связанных с интеграцией уже существующих и новых технологий облачных, граничных и туманных вычислений и обеспечивающих успешную реализацию на практике моделей, методов и алгоритмов интеллектуального проактивного (упреждающего) управления рассматриваемыми сложными техническими объектами (СТО) [1–3].

В отличие от традиционных производственных систем, такие производства характеризуются, во-первых, структурной изменчивостью технологических процессов, что влечет за собой динамичность параметров информационных потоков и вычислительных операций, и, во-вторых, предполагают высокий уровень автономности и адаптивности функционирования. В связи с этим для эффективного управления подобными СТО требуется разработка принципиально новых архитектурных решений, моделей, алгоритмов и программных платформ, предназначенных для координации

работы данных объектов и КФС, интегрированных в сеть ПриВ и с учетом функционирования их цифровых двойников (ЦД) [1–5].

Усложнение объектов и процессов промышленного производства, а также повышение степени ответственности лиц, принимающих и обосновывающих управленческие решения, обуславливают необходимость первоочередной стандартизации, автоматизации и интеллектуализации технологий проактивного управления ПриВ, что эквивалентно индустриализации самих многоуровневых, многоэтапных процессов проактивного управления. Это предполагает в практическом плане создание, эксплуатацию и развитие соответствующих автоматизированных, автоматических и информационно-управляющих систем (АСУ СТО, ИУС) [1,6]. Критически важным аспектом решения указанных задач является разработка специального математического, алгоритмического, программного и информационного обеспечения СМАО, СПИО), которые являются интеллектуальным ядром указанных сложных организационно-технических систем (СОТС).

С формальной точки зрения, разработка такого обеспечения связана с решением комплекса взаимосвязанных научно-технических проблем многокритериального многоэтапного, многоуровневого структурно-функционального синтеза облика ПриВ, а также программ проактивного управления их развитием [1, 3, 6]. Эти задачи отличаются высокой размерностью, нестационарностью и нелинейностью ограничений, необходимостью учета многочисленных НЕ-факторов, а также поиска компромиссных системотехнических решений при наличии нескольких противоречивых отношений предпочтения, заданных в количественной и качественной формах [7–9].

Методология и технологии автоматизации и интеллектуализации проактивного управления основными элементами и подсистемами ПриВ

В настоящее время, к сожалению, отсутствуют общая методология и технологии управления жизненным циклом (ЖЦ) цифровых двойников (ЦД) сложных объектов (СЛО), которые должны

быть синхронизированы с методологией и технологиями управления ЖЦ самих СЛО (ПриВ). Данное положение в еще большей мере становится актуальным в том случае, когда мы переходим от методологии и технологий традиционного реактивного управления к методологии и технологиям проактивного (упреждающего) управления структурной динамикой СЛО [1–3, 7–10]. Проактивное управление СЛО, в отличие от реактивного управления гарантированно обеспечивает своевременное принятие и реализацию обоснованных управленческих решений по срокам и объему мероприятий, связанных с переводом данного объекта в требуемое состояние за счет организации многовариантного упреждающего активного прогнозирования и оперативного парирования отклонений фактических значений компонентов вектора состояния и показателей качества функционирования СЛО от их прогнозных значений, используя при этом различные виды резервов.

Проведенные исследования показали, что данная методология должна включать в себя три базовые концепции, а также совокупность взаимосвязанных принципов [1–3, 10].

Первая концепция основана на принципах и технологиях комплексного (системного) моделирования СЛО (в данном случае – ПриВ). Она предполагает разработку новых методологических подходов к полимодельному описанию таких объектов их ЦД, а также создание и комбинированное использование разнотипных методов, алгоритмов и методик многокритериального анализа, синтеза и оптимизации выбора конкретных моделей и полимодельных комплексов (ПМК) для решения многочисленных актуальных инженерно-технических задач, существующих на практике. За счет предложенного авторами данного доклада системно-кибернетического описания процессов комплексного моделирования удастся данные процессы рассматривать как управляемые процессы, что позволяет ранее полученные ими результаты по управляемой конфигурации и реконфигурации СТО распространить на задачи структурно-функционального синтеза моделей и ПМК СЛО [1, 6, 7–8, 10].

Вторая концепция – это концепция проактивного (упреждающего) управления структурной динамикой СЛО и соответствующих ЦД, в том числе, АСУ СЛО, ИУС и их компоненты [1–5].

Третья концепция базируется на идеях и технологиях интеллектуализации процессов проактивного управления СЛО. При этом под интеллектуализацией управления СЛО будем понимать процесс повышения степени интеллектуальности управления, прежде всего, в направлении его адаптивности и автономности.

Рассматриваемая концепция лежит в основе новой парадигмы, требующей при управлении СЛО широкого использования, наряду с данными и информацией о СЛО и его системе управления (СУ), соответствующих знаний о конкретной предметной области, где функционирует СЛО (знаний явных, неявных, декларативных (знаний о чем-то), процедурных (знание осуществления процесса), каузальных, причинно-следственных и т. п., а также их комбинаций).

Ключевой аспект этой концепции – поиск конструктивных путей комплексирования (интеграции) естественного и искусственного интеллекта в целях повышения эффективности управления СЛО, к числу которых отнесен ПриВ [7–8, 10].

В работах [1–3, 6–8] подробно описаны методологические, технологические и организационно-технические принципы создания и функционирования СЛО и соответствующей АСУ СЛО (ПриВ).

Объединение перечисленных концепций, подходов и принципов в рамках предлагаемой методологии осуществляется на базе трех прикладных теорий, основные элементы которых представлены на рис. 1, рис. 2, рис. 3. В докладе также представлено системно-управленческое описание процессов создания и применения моделей и ПМК, которые открывает широкие перспективы привлечения фундаментальных и прикладных результатов, полученных к настоящему времени в междисциплинарной отрасли системных знаний для обоснованного выбора и использования требуемых моделей и ПМК [7–8].

В докладе предлагается трехуровневое описание процессов и системы проактивного управления (СПУ) ЖЦ как СЛО, так и их




Рис. 1. Методологические и методические основы теории проактивного мониторинга ЖЦ СЛО




Рис. 2. Методологические и методические основы теории проактивного управления ЖЦ СЛО




Рис. 3. Методологические и методические квалиметрии моделей и полимодельных комплексов, используемых при проактивном мониторинге и управлении ЖЦ Сло

ЦД. На первом уровне данной иерархии располагаются собственно процессы и технологии проактивного управления теми или иными Сло [1–3, 10].

На втором уровне предлагаемой иерархии располагаются непосредственно СМАО, СПИО проактивного управления (ПрУ) Сло (в нашем случае ПриВ), а также ЦД ПриВ, включающие в себя ЦМ, а также материальные, энергетические и информационные связи (каналы прямой и обратной связи), помощью которых осуществляется взаимодействие ЦД, ЦМ с Сло (ПриВ) [4–5].

На третьем уровне располагается МАО процессов параметрической, структурной и системной адаптации МАО второго уровня. В докладе обосновывается необходимость организации взаимодействия перечисленных уровней СПУ ЖЦ Сло и его ЦД на программно-информационном уровне в рамках ранее созданных отечественных имитационных систем (ИмС) [7–9], а также приведены примеры многоэтапной итерационной процедуры взаимодействия МАО, а также программно-информационного обеспечения перечисленных уровней СПУ ЖЦ Сло на примере ПриВ [3]. В работах [1, 2, 7] представлены содержание обобщенных процедур решения сформулированных задач, детали реализации, которых описаны в работах.

Заключение

В настоящее время при создании промышленного Интернета вещей одной из основных проблем была и остается проблема оперативного многокритериального синтеза технологий и программ проактивного управления материальными и информационными процессами в указанной территориально-распределенной информационно-управляющей системе (ИУС) с учетом ее постоянной структурной динамики [1, 2, 3, 6–10]. В докладе представлены разработанная методология и технологии автоматизации и интеллектуализации проактивного управления ЖЦ ПриВ.

Полученные результаты могут быть использованы, во-первых, для обоснования выбора наиболее предпочтительных технологий интеллектуального проактивного мониторинга состояний сложных-агро-биотехнических объектов на различных этапах ЖЦ, а также синтеза технологий проактивного управления многоспутниковой группировкой малоразмерных космических аппаратов, во-вторых, для выработки рекомендаций по применению соответствующего программно-математического обеспечения в целях повышения качества принимаемых управленческих решений в различных условиях обстановки.

Исследование выполнено за счёт гранта Российского научного фонда № 24-19-00823: <https://rscf.ru/project/24-19-00823>.

Библиография

1. **Охтилев М. Ю., Соколов Б. В., Юсупов Р. М.** Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. — М.: Наука, 2006. — 410 с.
2. **Юсупов Р. М., Соколов Б. В., Охтилев М. Ю.** Теоретические и технологические основы концепции проактивного мониторинга и управления сложными объектами // Известия Южного Федерального университета. Технические науки. — 2015. — № 1(162). — С. 162–174.
3. **Потрясаев С. А.** Синтез технологий и комплексных планов управления информационными процессами в промышленном интернете: дис. д-р тех. наук // СПб.: СПИИРАН. — 2020
4. Национальный стандарт Российской Федерации Р 57700.37-2021. Компьютерные модели и моделирование. Цифровые двойники. Основные положения. — 2021, 17 с.
5. **Серугендо Д. Д., Каттинг-Десель А. Ф., Гиз Л., Корменье Т., Хан И., Хоссенлоп Л.** Цифровые двойники: от концепций до промышленной эксплуатации. [Электронный ресурс] / <https://www.osp.ru/os/2022/04/13056597> (дата обращения 12.04.2023).
6. **Скурихин В. И., Забродский В. А., Копейченко Ю. В.** Адаптивные системы управления машиностроительным производством. — М.: Машиностроение, 1989. — 207 с.
7. **Соколов Б. В., Юсупов Р. М.** Концептуальные основы оценивания и анализа качества моделей и полимодельных комплексов // Теория и системы управления. — 2004. — № 6. — С.5–16.

8. **Микони С. В., Соколов Б. В., Юсупов Р. М.** Квалиметрия моделей и полимодельных комплексов. М.: РАН, 2018. — 314 с.

9. **Моисеев Н. Н.** Математические задачи системного анализа. — М.: Наука, 1981. — 488 с.

10. Litsam.ru: официальный сайт ЛИТСАМ [Электронный ресурс]. — URL: <http://litsam.ru> (дата обращения: 12.06.2025).

METHODOLOGY AND TECHNOLOGIES OF AUTOMATION AND INTELLECTUALIZATION OF PROACTIVE COMPLEX OBJECTS MANAGEMENT

Boris V. Sokolov¹, Valerii V. Zakharov

St. Petersburg Federal Research Center of the Russian Academy of Sciences,
St. Petersburg, Russia

¹sokolov_boris@inbox.ru

Abstract. The report presents the results of the development of theoretical foundations for solving problems of multi-level multi-criteria structural and functional synthesis of the appearance of a given segment of the domestic Industrial Internet of Things (IIoT), as well as information on the practical implementation of these theoretical foundations in the development of technologies for proactive control of a multi-satellite constellation of small-sized spacecraft, as well as in the management of complex agrobiotechnical objects. The proposed methodology and technologies for the automation and intellectualization of IoT proactive control processes are based on fundamental and applied results previously obtained by the authors of the report when performing complex research within the framework of the interdisciplinary branch of system knowledge.

Keywords. Complex objects, proactive management, industrial Internet of things, digital twins and digital models, qualimetry of models and multiple-model complexes, life cycle, multi-satellite constellations, agrobiotechnical objects.

* * *

ПРИМЕНЕНИЕ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ ДЛЯ НЕПРЕРЫВНЫХ ПРОЦЕССОВ ПОДГОТОВКИ И ПЕРЕРАБОТКИ НЕФТИ

Фарунцев Сергей Дмитриевич

Омский государственный технический университет, г. Омск, Россия
sdfar52@gmail.com

Аннотация. В работе приводятся результаты исследования различных вариантов систем интеллектуального управления (ИСУ) непрерывными теплотехническими процессами, применяемыми при переработке нефти и нефтепродуктов. Показано, что перспективным является способ управления с использованием аналитико-экспериментальной математической модели процесса. Применяются методы материального и теплового баланса, ячеечного моделирования, оптимизации, предиктивного управления, синтеза искусственных нейронных сетей. В качестве примера приведено описание модели и алгоритма нейроуправления ИСУ промышленным подогревателем нефтепродуктов П-1 установки каталитического риформинга Л-35-11/1000.

Ключевые слова. промышленный подогреватель нефтепродуктов, аналитико-экспериментальная модель, метод ячеечного моделирования, предиктивное управление, искусственная нейронная сеть, нейроконтроллер

Введение

В настоящее время в российской экономике не ослабевает внимание к отраслям промышленности, занятым переработкой органических и минеральных ресурсов с непрерывными технологическими процессами, к каковым относятся химическое производство, подготовка и переработка нефти и нефтепродуктов, энергетика, горно-добывающие комплексы и др. Актуальность применения интеллектуальных систем управления (ИСУ) в перечисленных ресурсных областях производства обусловлена зна-

чением данных отраслей для российской промышленности [1] и возможностями повышения качества продукции, экологической безопасности и эффективности, которые обеспечивают ИСУ основанные на современных программно-технических средствах управления.

Управление непрерывными технологическими процессами традиционными техническими средствами часто не отвечает современным требованиям, что связано со сложностью и многопараметрическим характером процессов, наличием возмущающих факторов, воздействующих на объекты управления, отсутствием, дефицитом или чрезмерной стоимостью автоматических анализаторов качества продуктов, различными организационными факторами, например, удаленностью многих производств от промышленных объектов (районы Сибири, Крайнего Севера и др.). Едва ли не единственным способом решения или частичной компенсации указанных проблем в нынешних условиях является разработка усовершенствованных и/или интеллектуальных систем управления. Под интеллектуальной понимается в настоящем рассмотрении такая система управления, которая позволяет принимать при наличии возмущающих контролируемых или неконтролируемых воздействий самостоятельные решения, основанные на анализе технологической ситуации и состояния объекта. Обязательным условием подобного машинного интеллекта является наличие адекватной математической модели (цифрового двойника, виртуальных анализаторов), позволяющей прогнозировать поведение объекта управления [2-4].

Но до сих пор остается открытым и активно обсуждаемым вопрос, какого рода модели использовать для синтеза ИСУ. Наиболее часто разработчики обращаются к экспериментально-статистическим методам моделирования (регрессионный и корреляционный анализ, искусственные нейронные сети), что представляется вполне естественным в силу наличия большого количества научных трудов, методик и т. п., посвященных применению математической статистики в промышленности и практике управления, и относительной (часто кажущейся) доступностью её использова-

ния в условиях производства. Однако данные методы обладают и существенными недостатками, вытекающими, главным образом, из критической зависимости экспериментально-статистических моделей от исходных данных необходимого качества и объема. Опыт показывает, что использование так называемой «пассивной статистики» в виде исторических данных, накапливаемых серверами АСУТП, в своем исходном виде мало пригодно для целей математического моделирования, особенно для построения динамических моделей, вследствие «засоренности» неконтролируемыми возмущениями, незавершенных переходных процессов и др. Применение «активной статистики» по методикам планирования оптимального эксперимента [5] может обеспечить лучшие результаты моделирования, но организационно-технические сложности использования методов активного эксперимента существенно ограничивают возможность их реализации в условиях реального производства.

Аналитические методы моделирования, основанные на использование базовых физических законов гидродинамики, тепло- и массопередачи и химической кинетики применяются до настоящего времени, как правило, только для целей предпроектного исследования. Непосредственное использование подобных методов для построения динамических моделей, пригодных для целей практического их применения в системах автоматического управления осложнено, как справедливо указывают авторы [4], их слабой формализуемостью, многомерностью, склонностью к смещению базисных констант уравнений в ходе эксплуатации.

Компромиссным в рассматриваемой ситуации является метод гибридного аналитико-экспериментального моделирования. В работе [3] приводятся, во-первых, перспективные области использования гибридных моделей в различных сферах управления, а во-вторых, предлагается один из вариантов построения гибридного алгоритма, сочетающего несложную аналитическую модель и искусственную нейронную сеть, обеспечивающую необходимую точность управления. В настоящей работе также делается акцент на применении гибридных аналитико-экспериментальных мо-

делей, но в иной, по сравнению с [3] реализации. Предлагается сформировать пакет аналитических балансовых моделей гидродинамики и теплотехники (пока рассматривается только теплотехнические процессы), содержащих конструктивные параметры объектов (масса, объемы, площади теплообмена и др.), коэффициенты теплопередачи между отдельными средами — газами горения, теплоносителями различного типа, металлом змеевиков, жаровых труб и др. Дополнительно модели подогревателей, использующих в качестве основного теплоносителя газы горения (промышленные печи) разделяются на отдельные зоны по типу теплообмена (радиационная и конвективная зоны) и виртуальные фрагменты — ячейки, обеспечивающие требуемую динамику движения теплоносителей и реализацию элементарных актов теплопередачи внутри каждой ячейки, т. е. в целом реализуется ячеечная методология моделирования [6–8].

Обычно, в теплотехнической инженерной практике коэффициенты теплопередачи берутся из литературы или рассчитываются по справочникам и по ним определяются проектные выходные данные, в частности, температура подогрева целевого продукта. В рассматриваемом случае имеется действующий объект, для которого фактические температуры уже известны, заданы регламентные данные входных и выходных параметров, известны реальные показатели эффективности (КПД), и перед нами стоит обратная задача — рассчитать (идентифицировать) по перечисленным известным данным численные значения базовых коэффициентов модели, которые наилучшим образом им удовлетворяют. Решается данная задача идентификации путем формирования и выполнения оптимизационной процедуры максимального приближения модели статике с рассчитываемыми коэффициентами к заданным параметрам функционирования и эффективности. После выполнения процедуры идентификации происходят синтез модели динамики её исследование и построение алгоритма управления. Выбор конкретного типа интеллектуального управления из возможного перечня — *MPC*-регулятора (*Model Predictive Controller*) или нейроконтроллера определенного вида, диктуется особенностями моде-

ли, ресурсам контроллера и иными факторами. В целом указанная методика достаточно подробно описана в статье [9] на примере путевого подогревателя нефти, применяемого на нефтегазовых месторождениях и трубопроводах. В настоящей работе рассматривается иной объект — промышленная печь П-1 установки каталитического риформинга Л-35-11/1000.

Описание ячеечной модели объекта управления

Установка Л-35-11/1000 в целом осуществляет риформинг (переработку) бензиновой фракции на полиметаллическом катализаторе с целью улучшения качества бензина (повышения его октанового числа). Печь П-1 осуществляет подогрев реагентов, подаваемых в каталитический реактор установки. Схема вертикальной печи П-1 показана на рис. 1. Температурный потенциал




Рис. 1. Схема печи П1

порядка 1900 °С создается за счет сгорания топливных газов *Fuel gas* и мазута *Fuel oil*, поступающих в нижнюю радиационную зону 1 печи и полностью сгорающих там при небольшом избытке воздуха. Смесь бензиновой фракции *Bfr* и водородосодержащего газа *Hgas* поступает при температуре около 230 °С первоначально в систему змеевиков конвекционной зоны 2 верхней части П-1, а затем переходит к змеевикам нижней радиационной зоны П-1, и выходит из печи в виде продукта *Oil*, подогретого до 300-320 °С. Тем самым обеспечивается наиболее экономичное противоточное движение горячих газов и нагреваемого продукта.




Рис. 2. Ячеечная модель подогревателя П-1

Отработавшие дымовые газы *Flue gases* через дымовую трубу 3 покидают печь. Рис. 2 иллюстрирует структуру, основные параметры ячеечной модели печи П-1, служащей основой дальнейших расчетов, и уровни изменения температуры всех участников теплообмена по длине подогревателя и от ячейки к ячейке — газов горения, металла змеевиков и подогреваемого нефтепродукта. На рис. 2 показано: 1 — газовая часть ячейки; 2 — металлическая часть ячейки; 3 — жидкостная часть ячейки; 4 — *i*-я ячейка в сборе (обведена пунктиром), 5 — камера (зона) сгорания; 6, 7, 8 — графики изменения температур газов горения, металла змеевиков и нефтепродукта, соответственно. Модель внутренней части печи разбита по её длине на *n* ячеек (*n* = 10), причем 1-я ячейка расположена на схеме слева со стороны ввода подогреваемых нефтепродуктов, имеющих температуру *Toil in*. На выходе из крайней правой *n*-й ячейки температура продукта равняется

Toil out. Первые 4 ячейки относятся к конвективной зоне, вторые 6 — к радиационной. Топливный газ и мазут подаются по схеме в камеру сгорания 4, где формируется температура T_{comb} , которая частично уменьшается до величины $T_{comb loss}$ за счет безвозвратной потери тепла E_{loss} . Температура металла во всех ячейках $Tw_1, Tw_i, \dots, Tw_n$ по величине занимает промежуточное положение между температурами газов и нефтепродукта, причем существенно смещенное в сторону последнего (вследствие большей величины коэффициентов теплоотдачи от металла к жидкости по сравнению с аналогичными коэффициентами от газов к металлу).

Температуры всех теплоносителей изменяются по длине печи от ячейки к ячейке ступенчато, причем в каждой части ячейки (газовой, металлической и жидкостной) эти температуры постоянны и одинаковы в каждой точке по всему объему (необходимое условие ячейечной модели). Второй и очень важной особенностью модели ячейки является тот факт, что температура каждого теплоносителя изменяется мгновенно при входе в ячейку (нефтепродукт в левой части ячейки по схеме, а газ — в правой, по ходу теплоносителей). На схеме рис. 2 также указаны (для i -ячейки, для остальных — аналогично): ε_i — поправочный коэффициент уравнения радиационного теплообмена, Вт/(м² · К⁴); β_i — соотношение радиационного и конвективного теплообмена в ячейке (отн. ед.); $\alpha_{gas i}$ — коэффициент теплоотдачи от газа к металлу змеевиков, Дж/(с · м² · К); Cp_i — изобарная теплоемкость смеси газов горения при температуре $T_{gas i}$, Дж/(м³ · К); λ_i — коэффициент теплопроводности материала (стали), Вт/(м · К); ρ_i — плотность материала, кг/м³; C_i — теплоемкость металла, Дж/(кг · К); $\alpha_{oil i}$ — коэффициент теплоотдачи от жидкости к металлу, Дж/(с · м² · К); $Coil_i$ — теплоемкость жидкого нефтепродукта при температуре $Toil i$, Дж/(м³ · К); v_{gas} — объемный расход газов горения (величина постоянная по длине печи), м³/с; $Goil$ — массовый расход нефтепродукта, кг/с (величина постоянная по длине печи); E_{loss} — безвозвратная потеря тепла в камере (зоне) горения, Дж/с.

Аналитико-экспериментальная модель статики печи П-1

Для целей идентификации теплофизических уравнений теплового баланса первоначально составляется система уравнений статики, включающая следующие расчетные зависимости.

— Температура $T_{comb loss}$ газов горения, поступающих в радиационную зону печи с учетом потери тепла в камере горения (таким образом в модели учтены безвозвратные потери тепла):

$$T_{comb loss} = T_{comb} = -\frac{E_{loss}}{v_{gas} \cdot Cp_{comb}}, \quad (1)$$

где T_{comb} — расчетное значение температуры горения топливного газа при отсутствии потерь теплоты, К; E_{loss} — потери теплоты в подогревателе, Вт; $T_{comb loss}$ — температуры газов на выходе камеры горения при наличии потерь тепла, равных E_{loss} , К; Cp_{comb} — теплоемкость газов в камере горения, Дж/(м³ · К).

— Тепловой поток $E1i$, Вт, передаваемый от газа к металлу в i -й ячейке:

$$E1i = [\beta_i \cdot \varepsilon_i \cdot Si \cdot 10^{-8} \cdot (T_{gas i}^4 - Tw_i^4) + (1 - \beta_i) \cdot \alpha_{gas i} \cdot Si \cdot (T_{gas i} - Tw_i)], \quad i = \overline{1, n}, \quad (2)$$

где Si — площадь поверхности теплообмена (змеевиков) в i -й ячейке (условно принимаются равными для внутренней и внешней частей змеевика), м²; Tw_i — температура металла в i -й ячейке, К.

— Тепловой поток $E2i$, Вт, переносимый газами горения в i -й ячейке:

$$E2i = v_{gas} \cdot [Cp_i \cdot T_{gas i} - Cp_{(i-1)} \cdot T_{gas(i-1)}], \quad i = 1, \dots, n. \quad (3)$$

— Тепловой поток $E3i$, Вт, передаваемый от металла змеевиков нефтепродукту в i -й ячейке:

$$E3i = \alpha_{oil i} \cdot Si \cdot (Tw_i - Toil i), \quad i = \overline{1, n}. \quad (4)$$

— Тепловой поток $E4i$, Вт по длине нефтепродуктовой части i -й ячейки:

$$E4i = Goil \cdot [Coil_i \cdot Toil i - Coil_{(i-1)} \cdot Toil_{(i-1)}], \quad i = 1, \dots, n. \quad (5)$$

– Тепловой поток $E5i$, Вт по длине металлической части i -й ячейки за счет теплопроводности металла и разницы температур на концах ячейки:

$$E5i = \frac{\lambda i \cdot Si}{\Delta x} \cdot [Tw(i-1) + Tw(i+1) - 2 \cdot Twi], i = \overline{1, n}, \quad (6)$$

где Δx – длина металлической части ячейки, м.

– Общий тепловой поток П-1 от газов горения $Etotal$, Вт:

$$Etotal = v_{gas} \cdot Cp(Tcomb) \cdot Tcomb, \quad (7)$$

где $Cp(Tcomb)$ – изобарная теплоемкость газов горения при температуре $Tcomb$, Дж/(м³·К).

– Тепловой поток $Egas out$, Вт, уносимый из печи дымовыми газами:

$$Egas out = v_{gas} \cdot Cp(Tgas out) \cdot Tgas out, \quad (8)$$

где $Cp(Tgas out)$ – изобарная теплоемкость газов горения при температуре уходящих газов $Tgas out$, Дж/(м³·К).

– Коэффициент эффективности (КПД) общий по печи $Keff total$, %:

$$Keff total = 100 \cdot (Etotal \cdot (1 - \Delta Eloss) - Egas out) / Etotal, \quad (9)$$

где $\Delta Eloss$ – относительная величина безвозвратных потерь (принята равной 1,5%).

– Коэффициент эффективности по газу $Keff gas$, %

$$Keff gas = 100 \cdot \sum_{i=1}^n E1i / Etotal. \quad (10)$$

– Коэффициент эффективности по нефтепродукту $Keff oil$, %

$$Keff oil = 100 \cdot \sum_{i=1}^n E4i / Etotal. \quad (11)$$

Уравнения (1)–(11) составляют основу задачи идентификации (расчета) следующих коэффициентов и параметров уравнений: εi , βi , $\alpha_{gas i}$, $\alpha_{oil i}$, $Tgas i$, $Tw i$, $Toil i$, $i = \overline{1, n}$, с учетом которых определяются численные значения показателей, рассчитываемых уравнениями (1)–(11). Решалась данная система нелинейных уравнений численными поисковыми методами. Критерием завершения

итерационного решения служит достижение следующих условий (с удовлетворительной точностью):

$$E1i = E2i = E3i = E4i, i = \overline{1, n}, \quad (12)$$

$$Keff total = Keff gas = Keff oil = Keff constr, \quad (13)$$

где $Keff constr$ – значение КПД печи П-1, заданное по проекту.

Исходные данные для постановки задачи идентификации были получены с одного из действующих объектов и дополнены экспертными оценками. На рис. 3 в графическом виде представлены некоторые результаты решения.




Рис. 3. Графики изменения по длине подогревателя (от первой ячейки к десятой) следующих параметров: 1 – температура газов горения, °С; 2 – температура металла змеевиков, °С; 3 – температура нефтепродукта, °С; 4 – относительная доля радиационного теплообмена по отношению к конвективному (отн. ед.)

При заданном значении КПД подогревателя $K_{eff\ constr} = 81\%$ были получены следующие достаточно близкие к проектной величине значения коэффициентов эффективности: $K_{eff\ total} = 80,8\%$, $K_{eff\ gas} = 80,6\%$, $K_{eff\ oil} = 80,6\%$.

Модель динамики печи

Система уравнений, описывающих гидродинамические и тепловые процессы печи в ячейках, имеет следующий вид.

– Изменение температуры газов горения в газовой части i -й ячейки:

$$V_{gas\ i} \cdot \left(\frac{\partial C_{pi}}{\partial T_{gas\ i}} + \right) \cdot \frac{\partial T_{gas\ i}}{\partial t} = E_{2i} - E_{3i}, \quad i = \overline{1, n}, \quad (14)$$

где $V_{gas\ i}$ – объем газовой части i -й ячейки, m^3 .

– Изменение температуры в металлической части i -й ячейки:

$$M_i \cdot \left(\frac{\partial C_i}{\partial T_{wi}} \cdot T_{wi} + C_i \right) \cdot \frac{\partial T_{wi}}{\partial t} = E_{2i} - E_{3i} + E_{5i}, \quad i = \overline{1, n}, \quad (15)$$

где M_i – масса металлической части i -й ячейки, кг.

– Изменение температуры в нефтепродуктовой части i -й ячейки:

$$V_{oil\ i} \left[C_{oil\ i} \cdot \rho_{oil\ i} + T_{oil\ i} \cdot \left(C_{oil\ i} \cdot \frac{\partial \rho_i}{\partial T_{oil\ i}} + \rho_i \cdot \frac{\partial C_i}{\partial T_{oil\ i}} \right) \right] \cdot \frac{\partial T_{oil\ i}}{\partial t} = E_{3i} + E_{4i}, \quad i = \overline{1, n}, \quad (16)$$

где $V_{oil\ i}$ – объем нефтепродуктовой части i -й ячейки, m^3 .

Решение системы (14)–(16) из тридцати нелинейных дифференциальных уравнений в частных производных ($n = 10$) выполнялось численными методами с применением методологии ячейечного моделирования и с использованием расчетных коэффициентов, полученных на предыдущем этапе идентификации. Рис. 4 иллюстрирует качественные результаты расчетов в виде реакции различных параметров динамической модели объекта управления на импульсное воздействие по входному каналу начальной температуры нефтепродукта.




Рис. 4. Графики реакции параметров температуры газов горения на выходе печи (слева), нефтепродукта на выходе печи (в центре) и температуры металла змеевика в конечной точке (справа) на импульсное воздействие со стороны входной температуры нефтепродукта

Синтез модели системы предиктивного управления П-1

Последовательность синтеза схемы предиктивного управления при наличии известной математической модели объекта включает несколько этапов. Поскольку непосредственно использовать в составе контроллера аналитическую модель, включающую десятки дифференциальных уравнений достаточно проблематично, целесообразно первоначально рассматривать полученную модель динамики П-1, как эталонную (референсную), но при этом построить эмулятор, т.е. динамический аналог эталонной модели, достаточно простой, чтобы его можно было использовать в составе программного обеспечения промышленных контроллеров и, в то же время, обладающего необходимой точностью воспроизведения статических и динамических свойств объекта управления. Наличие эталонной модели позволило получить подобный динамический эмулятор П-1 в виде четырехходовой двухуровневой ИНС прямого распространения, реализующей с достаточной точностью расчет температуры подогрева нефтепродукта *Toil out* по зависимости

$$Toil\ out = f(v\ gas, Tcomb, Goil, Toil\ in),$$

где аргументы функции (17) включают управляющее воздействие (*v gas*) и основные возмущающие параметры процесса (*Tcomb*, *Goil*, *Toil in*).

На следующем этапе производился анализ возможных способов построения системы предиктивного управления подогревателем, их исследование и выбор оптимального варианта. Рассмотрены следующие методы управления — *MPC*-регулятор (*Model Predictive Controller*), многопараметрический *MISO NARMA L2* контроллер, инверсный нейроконтроллер и гибридный вариант инверсного нейроконтроллера и пропорционально-интегрального (ПИ) регулятора. Подробно излагать результаты каждого из исследования отсутствует возможность из-за дефицита места в публикации, тем более что методических материалов по описанию указанных методов в открытой печати достаточно (см. пособие по нейроуправ-

лению [10]). Следует только отметить достаточно свежий пример разработки многопараметрического *MISO NARMA L2* нейроконтроллера [11].

На рис. 5 изображена схема модели гибридного управления, составленной из инверсного нейроконтроллера и ПИ-регулятора. Особенность подобной гибридной схемы заключается в том, что в ней совмещаются достоинства двух самых распространенных принципов управления — «по возмущению» (за счет инверсного нейроконтроллера) и «по отклонению» (за счет ПИ-регулятора). Такая схема оперативно реагирует на контролируемые возмущения, не дожидаясь, пока их действие скажется на качестве выходного продукта, и способна компенсировать действие неконтролируемых возмущений, пропущенных инверсным контроллером и наличие которых неизбежно на любом реальном производстве.

Инверсный регулятор, построенный на основе четырехходовой двухуровневой ИНС прямого распространения (подобно прямому эмулятору объекта), решает задачу (18), обратную (17), т. е. вычисляет величину управляющего воздействия *v gas*, необходимую для поддержания заданного значения регулирования температуры подогрева нефтепродукта в условиях действия контролируемых возмущений:

$$v\ gas = f(Toil\ out\ set, Tcomb, Goil, Toil\ in),$$

где *Toil out set* — заданное значение регулирования температуры подогрева нефтепродукта, °С. Схема модели гибридного нейроуправления показана на рис. 5.

Схема включает следующие подсистемы и блоки: *Subs_Data_Gen* — генератор возмущений; *Toil out set* — блок задания регулятором; *ANN_PI_inv* — блок инверсного нейрорегулятора; *Subs_PI* — подсистема модели объекта управления (эталонная динамическая модель печи П-1); *PI-Controller* — блок ПИ-регулятора; *Subs_To_Workspace* — блок передачи информации в рабочее пространство для последующего статистического анализа качества регулирования; *Compare To Constant* — логический блок формирования разрешения передачи информации (для отсечки непредставительного




Рис. 5. Схема модели гибридного пропорционально-интегрального и инверсного нейруправления П-1




Рис. 6. Графики изменения параметров схемы регулирования: 1 – температура газов горения, °C; 2 – расход нефтепродукта, кг/с; 3 – температура нефтепродукта на входе, °C; 4 – расход газа (управляющий параметр), м³/с; 5 – температура нефтепродукта на выходе (управляемая переменная), °C; 6 – заданное значение температуры подогрева, °C

начального участка переходных процессов). Рис. 6 демонстрирует в графическом виде результаты работы схемы регулирования. На рисунке показаны графики изменения возмущающих параметров (графики 1, 2, 3), график изменения регулируемого параметра (кривая 4) и график заданного значения (прямая 5). Качество регулирования схемы, оцениваемое по величинам дисперсии ($\sigma^2 = 0,33$), среднеквадратичного отклонения ($\sigma = 0,58$ °C) значения температуры подогрева нефтепродукта от заданного значения (310 °C) и 95 % отклонения (3σ), для рассматриваемого случая составило

$$Toil\ out = Toil\ out\ set \pm 3\sigma = 310 \pm 1,72\ ^\circ C.$$

Заключение

1. Приведены результаты исследования вариантов систем интеллектуального управления непрерывными теплотехническими процессами, используемыми при переработке нефти и нефтепродуктов.

2. В качестве основы для построения модели выбран и обоснован перспективный ячеечный метод аналитико-экспериментального моделирования, совмещающий аналитическое описание процесса и экспериментальную подстройку базисных коэффициентов уравнений материального и теплового баланса.

3. Приведены уравнения статики и динамики модели подогревателя П-1 установки каталитического риформинга Л-35-11/1000, построенные с использованием методологии ячеечного моделирования, и результаты расчетов по данным моделям, позволившие вычислить численные значения теплотехнических коэффициентов и тепловой режим подогревателя в целом.

4. Приведены результаты синтеза интеллектуальной системы управления подогревателем П-1, описана модель и результаты испытания гибридной схемы инверсного нейроконтроллера и ПИ-регулятора, совмещающей достоинства схем по возмущению и по отклонению.

Библиография

1. Ресурсные регионы России в «новой реальности» / Под ред. акад. Кулешова В.В. — Новосибирск: Изд-во ИЭОПП СО РАН, 2017. — 308 с.
2. **Веревкин А. П.** Методы решения «продвинутых» задач управления и обеспечения безопасности для объектов нефтегазового комплекса / Веревкин А.П. // Тр. всероссийской научно-технич. конф. «Проблемы управления и автоматизации технологических процессов и производств». Уфа. 2010. С. 8 — 23.
3. **Дозорцев В. М.** Цифровые двойники в промышленности: генезис, состав, терминология, технологии, платформы, перспективы. Ч. 2. Ключевые технологии цифровых двойников. Типы моделирования физического объекта / Дозорцев В.М. // Автоматизация в промышленности. — 2020. — № 11. — С. 3—10.
4. **Торгашов А. Ю.** Современные методы построения систем усовершенствованного управления технологическими процессами / Торгашов А. Ю., Гончаров А. А., Самотылова С. А. // Вестник ДВО РАН. — 2016. — № 4. — С. 102—107.
5. **Ахназарова С. Л.** Методы оптимизации эксперимента в химической технологии / Ахназарова С.Л., Кафаров В.В. — М.: Высшая школа, 1985. — 165 с.
6. **Хамухин А. А.** Ячеечная модель устройства для решения дифференциальных уравнений в частных производных / Хамухин А.А. // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. — 2010. — Т. 316, № 5. — С. 63—67.
7. **Торгашев А. Ю.** Моделирование динамики и исследование оптимального функционирования теплообменного технологического процесса / Торгашев А.Ю. // Информатика и системы управления. — 2011. — № 2(28). — С. 86—93.
8. **Faruntsev S. D.** Method for Creation of Cell Models and Universal Tool for the Development of Mathematical Models of Dynamics Used to Perform Smart Control of Oil Production Facilities / Faruntsev S.D. // Journal of Physics: Conference Series. — 2020. — Vol. 1546. — P. 012012.
9. **Фарунцев С. Д.** От цифрового двойника к системам интеллектуального управления. Синтез гибридной модели управления теплотехническими объектами установок подготовки нефти / Фарунцев С.Д. // Автоматизация в промышленности. — 2023. — № 2. — С. 3—14.
10. **Бураков М. В.** Нейронные сети и нейроконтроллеры : учеб. пособие / М. В. Бураков // СПб. : ГУАП, 2013. — 284 с.
11. **Фарунцев С. Д.** Многопараметрический нейрорегулятор для подогревателя нефтяной эмульсии / Фарунцев С.Д. // Автоматизация в промышленности. — 2024. — № 11. — С. 23—29.

APPLICATION OF INTELLIGENT CONTROL METHODS FOR CONTINUOUS OIL PRODUCTION AND REFINING PROCESSES

Sergey D. Faruntsev

Omsk State Technical University, Omsk, Russia

sdfar52@gmail.com

Abstract. The paper presents the results of a study of various variants of intelligent control systems (ICS) for continuous thermal processes used in the refining of oil and oil products. It is shown that the control method using an analytical and experimental mathematical model of the process is promising. The methods of material and heat balance, cell modeling, optimization, predictive control, and synthesis of artificial neural networks are used. As an example, a description of the model and algorithm of neural control of the ISU of the industrial heater of petroleum products P-1 of the catalytic reforming unit L-35-11/1000 is given.

Keywords. Industrial heater of oil products, analytical and experimental model, cell modeling method, predictive control, artificial neural network, neurocontroller

* * *

УДК 006.91+004.896+413.4

doi:10.18720/SPBPU/2/id25-516

ИЗМЕРЕНИЯ И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ. НОВЫЙ ЭТАП

Тайманов Роальд Евгеньевич¹, Сапожникова Ксения Всеволодовна²

Всероссийский научно-исследовательский институт метрологии
им. Д. И. Менделеева Санкт-Петербург Россия

¹taymanov@vniim.ru, ²k.v.s@vniim.ru

Аннотация. Применение искусственного интеллекта (ИИ) в системах, используемых в промышленности, сельском хозяйстве, медицине и т.д. повышает эффективность деятельности в этих областях. В измерительных системах ИИ позволяет решать задачи в случае неполной информацией об объектах и условиях измерений. Одновременно нарастают риски и не-

обходимость их ограничений. В статье обсуждаются проблемы стандартизации в области ИИ и подходы к снижению рисков использования этих систем. На основе опыта Росстандарта предлагаются организационные меры.

Ключевые слова. Искусственный интеллект, измерения, система на основе искусственного интеллекта, риски применения, стандартизация, экспертиза.

Введение

С начала этапа Индустрии 4.0 применение систем на основе искусственного интеллекта (ИИ) становится все более разнообразным, а в перспективе, с наступлением этапа Индустрии 5.0, жизненно важной задачей цивилизации, связанной как с резко возрастающими возможностями, так и с нарастающими рисками.

Измерение свойств, характеризующих физиологию человека и взаимосвязи его внутренних органов, его способности, знания и возможности, окажется реальным при использовании систем на основе ИИ. Более того, такие системы позволят количественно оценить динамику изменения названных свойств и принять меры, которые дадут возможность улучшить здоровье граждан и повысить их удовлетворенность жизнью.

ИИ поможет выявить потребности граждан, проживающих в том или ином районе. Станет очевидна степень их удовлетворенности энергетическими ресурсами, питьевой водой и качеством воздуха, достаточностью количества школ, магазинов, банков, клиник и т. д. В сочетании с максимальной поддержкой со стороны муниципальных организаций, все это позволит сформировать комфортную социальную среду.

Комплексная автоматизация с помощью систем на основе ИИ, встроенных в аппаратуру управления средств городского транспорта, а также в облачные комплексы, обеспечивающие оптимизацию транспортных потоков, позволит доставить пассажира безопасно и быстро в требуемое место. Системы на основе ИИ резко повысят эффективность оборудования, используемого в энергетике, оборонной технике, сельском хозяйстве, добывающей промышленности, в научных исследованиях, в том числе в космосе, и т. д.

Метрология как «наука наук» [16, 18] должна способствовать повышению надежности перечисленных выше грандиозных преобразований, обусловленных применением систем на основе ИИ, и минимизации потенциальных рисков, связанных с их использованием.

Средства измерений на основе ИИ на этапе Индустрии 4.0

Особенности применения. Для средств измерений (СИ), включая измерительные системы, на основе ИИ (СИИИ) с начала 2-го десятилетия 21 века характерно:

- применение облачных технологий,
- быстрое увеличение количества многопараметрических величин, измерение значений которых оказывается востребованным.

Ниже приведены примеры разработок СИИИ, в которых авторы настоящей статьи принимали участие:

- диагностика состояния здоровья, учитывающая взаимосвязь различных компонентов организма, позволяющая выявлять заболевания в начальной стадии [9];
- автоматическое управление производственным оборудованием, в котором в процессе работы узлов с повышенной нагрузкой для увеличения эффективности работы оборудования применяется сравнение фактического состояния узлов, описываемого многопараметрической величиной, со статистически обоснованной моделью этой величины [17];
- расшифровка содержания эмоционально окрашенных акустических сигналов, издаваемых животными [15].

При измерении многопараметрических величин каждый из параметров должен являться измеряемой величиной с четко ограниченным диапазоном измерений и заданными условиями. Как правило, такие измерения требуют предварительных метрологических исследований с участием специалистов различных областей знаний.

Применение систем на основе ИИ связано с интенсивной цифровизацией потоков поступающей информации практически во всех сферах жизни. В метрологии цифровизация означает:

- массовый переход к цифровым эталонам и датчикам с цифровым выходом, включая датчики с встроенными нейронными сетями;

- прогнозирование изменения значений измеряемых величин за интервал времени между поверками/ калибровками;

- автоматизацию контроля достоверности результатов измерений.

- использование референтных методик для обеспечения метрологической прослеживаемости в более широкой области измеряемых величин.

Цифровизация дает возможность расширить объем метрологических исследований, требующих участия специалистов различных областей знаний. Такое творческое содружество особенно необходимо при разработке методов измерения многопараметрических величин, в том числе, с использованием СИИИ.

СИИИ от традиционных средств измерений отличает:

- многозадачность использования;

- большое количество разнообразных компонентов в аппаратуре и высокая ее стоимость, особенно, в случае применения сильного ИИ;

- повышенная вероятность ухудшения метрологических характеристик на интервале между поверками / калибровками, обусловленная многокомпонентностью аппаратуры и воздействием помех;

- отсутствие прозрачности и объяснимости алгоритмов получения результатов измерений в случае использования сильного ИИ.

Особенности стандартизации в области СИИИ на этапе Индустрия 4.0. Расширение сферы применения систем на основе ИИ связано с постепенным увеличением среди них доли систем с сильным интеллектом. Растет значимость негативных последствий, обусловленных возможными нарушениями в их работе. Это касается и СИИИ.

Названная тенденция вызвала рост количества стандартов, устанавливающих требования к структуре систем на основе ИИ и

правилам работы с ними. В российском ТК 164 «Искусственный интеллект», который является зеркальным комитету ISO SC 42 “Artificial Intelligence”, с 2019 года утверждено более 100 ПНСТ и ГОСТ Р как общего характера, так и связанных с конкретными областями применения таких систем.

Наряду с различными проектами СИИИ, все чаще появляются проекты, касающиеся систем на основе ИИ, которые ориентированы на обработку потоков цифровых данных, в основном, не связанных с измерительной информацией. Эти проекты формулируют правила обработки, способствующие повышению достоверности их результатов.

Большинство российских стандартов относится к системам, в том числе, СИИИ, на основе слабого интеллекта, алгоритм работы которых известен. Ситуация постепенно меняется.

Утверждены и вступили в силу два ГОСТ Р, которые разработаны в Государственном научном центре ФГУП «ВНИИМ им. Д. И. Менделеева» [5, 6], относящиеся к СИИИ.

В них учитываются возможности:

- использования как слабого, так и сильного ИИ;

- повышения достоверности измерительной информации за счет метрологического самоконтроля (МСК);

- измерения многопараметрических величин;

- использования информации, поступающей не только от различных датчиков и мер, но и из базы знаний, а также от экспертов и испытуемых.

Нередко в проектах встречаются проявления небрежности и даже некомпетентности. Выявление такого рода дефектов, и подготовка предложений по их устранению отнимает много времени у специалистов различных организаций, которым проекты направлены на отзыв или экспертизу. В ряде случаев специалисты, которых эти проекты не заинтересовали, их одобряют, не анализируя.

Для повышения качества стандартов, подготавливаемых в ТК164, во ВНИИМ в инициативном порядке ведется работа, ориентированная на автоматизацию экспертизы соответствующих проектов [1].

Риск применения систем на основе ИИ. Важнейшей проблемой, связанной с использованием систем на основе ИИ, большинство исследователей считают риск нежелательных последствий. Этот риск обусловлен, в первую очередь, применением систем с сильным интеллектом в наукоемких автоматических комплексах — в космической отрасли, в медицине, в оборонной технике, в энергетике (в том числе атомной), на транспорте, в подвижных роботах и т. д.

Риск порожден отсутствием информации о реализуемых в таких системах алгоритмах работы. Он усугубляется высокой вероятностью в достаточно близком будущем организации обмена информацией между системами на основе ИИ, относящимся к различным комплексам, и формирования между ними социальных связей.

Опасные последствия неконтролируемого развития ИИ рассматриваются во многих книгах и статьях, обсуждаются на международных Конгрессах и конференциях.

Не случайно Регламент Европейского Союза (ЕС) об ИИ [11], утвержденный в 2024 г. посвящен рискам, которые будут нарастать для общества по мере распространения комплексов на основе ИИ, и потенциальным возможностям их избежать.

Регламент включает:

- правила размещения на рынке, ввода в эксплуатацию и использования систем на основе ИИ;
- запреты на определенные методы реализации ИИ;
- особые требования к системам на основе ИИ с высоким уровнем риска;
- гармонизированные правила прозрачности преобразований информации для ряда систем на основе ИИ;
- правила мониторинга рынка систем на основе ИИ и управления надзором за рынком.

В Регламенте приведены требования к разработчикам, поставщикам, импортерам, дистрибьюторам, а также к системам и моделям, принятым для разработки. К запрещенным методам ИИ Регламент, относит, в первую очередь те, которые могут воздей-

ствовать на человека на подсознательном уровне, приводить к физическому и психологическому ущербу. Высокий риск характерен для ряда систем, предназначенных для использования в качестве детекторов лжи, распознавания эмоций, оценки качества образования, связанных с управлением миграцией и т.д.

В качестве верхнего звена создается специальная Комиссия ЕС. Каждое государство, входящее в состав ЕС, должно создать органы, ответственные за мониторинг ситуации с системами на основе ИИ. Эти органы должны немедленно уведомлять Комиссию о любом серьезном инциденте. В свою очередь, Комиссия должна в сотрудничестве с государствами-членами создать и поддерживать базу данных по системам ИИ высокого риска. ЕС продемонстрировал жесткий подход к регулированию применения ИИ: фактически это централизованный контроль всех стадий разработки и применения нейросетей с тщательным их тестированием перед использованием.

Одновременно с разработкой и согласованием Регламента шла подготовка стандартов по управлению рисками [7, 12].

В отличие от ЕС в США, в Великобритании и Японии предусмотрен минимальный контроль ИИ. В Китае законодатели стремятся найти баланс между безопасностью и развитием.

В России предложено правила работы с ИИ постепенно корректировать, учитывая тенденцию к саморегулированию и распространенность риск-ориентированного подхода при разработке систем на основе ИИ [10]. Все сферы, в которых они могут применяться, разделены на группы.

В первой должны находиться системы с недопустимым уровнем риска, например, связанные с вынесением судебных решений или постановкой окончательных медицинских диагнозов.

Вторая группа включает системы с высоким риском, влияющие на решения, касающиеся образования, инфраструктуры, транспорта и т. д.

К третьей относятся системы с ограниченным риском, где ИИ можно применять, если люди будут знать, что они взаимодействуют с ИИ.

Четвертая группа связана с минимальным риском при использовании ИИ: например, в видеоиграх, в программах для фильтрации спама.

Названные документы рожают ряд вопросов и, в первую очередь, вопрос о том, какие государственные организации должны принимать решения об отнесении конкретной системы к той или иной группе и о реализации контроля выполнения требований [7, 10].

Имеется эффективный опыт проведения такой метрологической процедуры как утверждение типа средств измерений. Характерно, что наблюдение за соблюдением действующих национальных стандартов в различных странах обычно выполняют метрологические организации.

Более того, при утверждении типа СИ, в том числе СИИИ, в России и в ряде других стран принято оценивать наличие в СИ средств МСК.

Средства МСК, исключают возможность работы СИ при возникновении неисправности в какой-либо цепи, важной для достоверности результата, т.е. обеспечивают безопасность функционирования с позиции метрологии. Они дают оператору сигнал о необходимости остановить оборудование или автоматически устраняют неисправность. Для устранения неисправности можно использовать коррекцию искаженных параметров или отключение неисправной цепи и подключение цепи резервной (избыточной). Эти методы принято именовать МСК с автоматической коррекцией (МСКАК). Методы МСК и МСКАК впервые разработаны во ВНИИМ [8, 14], а их возможности и способы реализации описаны в нескольких стандартах России [2-4]. Они введены в стандарт ISO [13], а также (с иной терминологией и для ограниченного количества измеряемых величин) в стандарты Великобритании и ряда других стран.

СИИИ обычно встраивают в дорогостоящее оборудование. Как следствие, при предсказании его состояния встроенными в него СИИИ с МСК и МСКАК, можно существенно повысить эффективность этого оборудования. Причина — сокращение про-

стоев, обусловленных метрологическим обслуживанием с традиционным выбором длительности межповерочного или межкалибровочного интервала.

В совокупности, рассмотренная выше практика дает основание поручить именно метрологам надзор за реализацией требований по обеспечению безопасности применения систем на основе ИИ.

Пути совершенствования систем на основе ИИ

Предложения авторов, касающиеся государственной деятельности в этом направлении. Целесообразно продолжать практику участия представителей России в разработке стандартов ISO, посвященных системам на основе ИИ. Полезен их перевод, а в ряде случаев и утверждение в качестве национальных стандартов с модификацией, учитывающей принятое в стране законодательство.

Государственным научным центрам (ГНЦ) Росстандарта было бы полезно поручить разработку методов выявления применяемых систем на основе ИИ и анализ достаточности мер, принятых для уменьшения сопутствующего риска. Для повышения эффективности этой работы следовало бы привлекать названные ГНЦ к разработке актуальных для стран систем на основе ИИ с сильным интеллектом.

Большим вкладом в решение рассматриваемой проблемы может стать разработка государственной схемы сертификации систем на основе ИИ с приемлемым риском использования. В этой схеме должны быть учтены методы, разработанные ведущими ГНЦ. Она должна быть ориентирована на создание единого представления о степени безопасности (подобного представлению о прослеживаемости результатов измерений).

Предложения, касающиеся повышения надежности. По аналогии с МСК и МСКАК, целесообразно дополнять системы на основе ИИ средствами диагностики. При обнаружении дефектов эти средства должны формировать соответствующие сигналы оператору. Системы на основе ИИ, относящиеся к группе с высоким риском использования, полезно комплектовать средствами авто-

матической коррекции искажений, а также резервными цепями и средствами автоматического переключения части информационного потока на эти цепи. Предлагаемые меры существенно ограничат вероятность разработки и незаконного распространения опасных для общества систем с ИИ, в том числе содержащих как технические, так и биологические компоненты.

Заключение

В статье кратко изложены проблемы, требующие кардинальных изменений в подготовке и работе метрологов.

Необходимо не только практически непрерывное повышение квалификации, но и воспитание готовности найти и принять решение, направленное на предотвращение масштабных экономических потерь и человеческих трагедий.

Библиография

1. **Аминова А. С.** Метрологическая экспертиза проектов стандартов: перспектива разработки нейронной сети для автоматизации процесса. // Прикладной искусственный интеллект: перспективы и риски. — Сборник докладов Международной научной конференции. — 2024. — С. 10–14.
2. ГОСТ Р 8.673–2009. ГСИ. Датчики интеллектуальные и системы измерительные интеллектуальные. Основные термины и определения.
3. ГОСТ Р 8.734–2011. ГСИ. Датчики интеллектуальные и системы измерительные интеллектуальные. Методы метрологического самоконтроля.
4. ГОСТ Р 8.825–2013. ГСИ. Датчики интеллектуальные и системы измерительные интеллектуальные. Методы ускоренных испытаний.
5. ГОСТ Р 71561–2024. Средства измерений на основе искусственного интеллекта. Состав, структура и области применения. Основные положения.
6. ГОСТ Р 71562–2024. Средства измерений на основе искусственного интеллекта. Метрологическое обеспечение. Общие требования.
7. ПНСТ 766–2022. Информационные технологии. Интеллект искусственный Управление рисками.
8. **Сапожникова К. В., Тайманов Р. Е., Кочугуров В. В.** Метрологический контроль как компонент диагностики гибких производственных систем и робототехнических комплексов // Испытания, контроль и диагностирова-

ние в гибких производственных систем (по материалам семинара 1985 г. в ИМАШ АН им. А. А. Благонравова). М.: Наука, 1988. — С. 269–273.

9. **Успенский В. М.** Новые возможности в диагностике заболеваний // Информационные и телекоммуникационные технологии. — 2022. № 55. — С. 24–31.

10. Человек, ИИ, закон. <https://iz.ru/1701186/sergei-gurianov/chelovek-ii-zakon-kak-v-rossii-budut-regulirovat-iskusstvennyi-intellekt>.

11. EU Artificial Intelligence Act.

12. ISO/IEC 23894:2023 Information technology. Artificial intelligence — Guidance on Risk Management.

13. ISO/IEC CD TR 5469 Artificial intelligence — Functional Safety and AI Systems.

14. **Sapozhnikova K., Pronin A., Taymanov R.** Increasing measurement trustworthiness as a necessary part of technology development, *Sensors & Transducers*, vol. 251(4), pp. 61–69, 2021.

15. **Sapozhnikova K., Taymanov R., Baksheeva Iu., Danilova I.** Measurements as the basis for interpreting the content of emotionally coloured acoustic signals, *Measurement*, vol. 202, art. no. 111861, pp. 1–12, 2022.

16. **Sapozhnikova K., Taymanov R., Kostromina S.** On the eve of the new leap in measurement science, *J. Phys.: Conf. Ser.*, vol. 1703, art. no. 012001, pp. 1–9, 2020.

17. **Shestakov A., Sapozhnikova K., Taymanov R., Sinitsin V.** Metrological self-checking and self-diagnosing as a characteristic feature of automated production development in the Industry 4.0 era, *Measurement: Sensors*, art. no. 101508, 2024.

18. **Witkovský V., Frollo I.** Measurement science is the science of sciences — There is no science without measurement, *Measurement, Science Review*, 20(1), pp. 1–5, 2020.

MEASUREMENTS AND ARTIFICIAL INTELLIGENCE. A NEW STAGE

Roald Ye. Taymanov¹, Kseniia V. Sapozhnikova²

D. I. Mendeleyev Institute for Metrology, St. Petersburg, Russia,

¹taymanov@vniim.ru, ²taymanov@vniim.ru

Abstract. The integration of artificial intelligence (AI) into systems employed across industrial, agricultural, medical sectors, etc. enhances operational efficiency within these domains. In measuring systems, AI facilitates problem-sol-

ving under incomplete information regarding measurement objects and conditions. Concurrently, risks and the need for their limitation are growing. The article examines the challenges related to the standardization of AI technologies and explores methodologies aimed at reducing corresponding risks. Based on the expertise of Rosstandart, a set of organizational measures is proposed to address these challenges.

Keywords. Artificial intelligence, measurements, artificial intelligence-based system, risks of application, standardization, expertise.

* * *

УДК 004.896

doi:10.18720/SPBPU/2/id25-517

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ В СИСТЕМЕ ОБЕСПЕЧЕНИЯ ЕДИНСТВА ИЗМЕРЕНИЙ

Миргородская Анастасия Викторовна^{1,a}, Фот Наталия Павловна^{2,b}

¹Всероссийский научно-исследовательский институт метрологии
им. Д.И. Менделеева, Санкт-Петербург, Россия,

²Оренбургский государственный университет, г. Оренбург, Россия

^aa.v.mirgorodskaya@vniim.ru, ^be-mail fotnp@mail.ru

Аннотация. В статье рассматривается возможность построения нейросетевых моделей на основе алгоритмов машинного обучения в метрологии для автоматизации процесса измерения времени истечения жидкости при поверке стеклянных капиллярных вискозиметров. Подчеркивается важность цифровой трансформации для обеспечения единства измерений. Предлагается подход, базирующийся на применении считывающих устройств, автоматического формирования базы данных с возможностью их дальнейшей обработки при принятии решений. Описаны этапы подготовки данных, включая распознавание рисков на вискозиметре и учет параллакса, а также применимость методов машинного обучения «с обучением» и «без обучения». Внедрение данного подхода снизит влияние человеческого фактора и будет соответствовать современным требованиям цифровизации и автоматизации в метрологии.

Ключевые слова. машинное обучение, кластеризация, цифровая метрология, автоматизация измерений, распознавание образов, обработка изображений.

Введение

Обеспечение единства измерений является необходимой базой большого количества научных исследований, развития промышленного производства и сферы государственного регулирования. Сопоставимость результатов измерений критически важна для международной торговли, стандартизации и контроля качества [1] и в России эти функции возложены на Федеральное агентство по техническому регулированию и метрологии (Росстандарт), с 2004 года находящегося в ведении Министерства промышленности и торговли Российской Федерации [2].

Одной из задач, выполняемой Росстандартом, является поддержание и актуализация первичных эталонов. Однако, с целью соответствия современным требованиям, которые диктует новый технологичный мир, например, развитие квантовой метрологии [3], освоение космоса, развитие цифровой метрологии [4–6], ряд эталонов нуждаются в модернизации с применением современных цифровых инструментов. К таким эталонам, например, требующим доработки в части способа определения интервала времени истечения жидкости, относят эталон кинематической вязкости. Учитывая опыт зарубежных коллег [7, 8], у которых этап определения времени истечения жидкости автоматизирован, возникает вопрос: почему нечто подобное не организовать при поверке рабочих средств измерений (вискозиметров стеклянных капиллярных)? Следующим вопросом является – как и с помощью каких современных цифровых инструментов это реализовать? Очевидно – с применением устройств, позволяющих считывать и создавать базу данных с дальнейшей обработкой полученных результатов посредством построения нейросетевых моделей на основе алгоритмов машинного обучения.

Данная задача полностью соответствуют современным требованиям, определенным в Стратегии обеспечения единства измерений в Российской Федерации до 2025 года, как по автоматизации некоторых этапов периодической поверки, так и по обеспечению экономической эффективности их автоматизации [9].

Кроме того, внедрение цифровых решений в метрологию уже является одной из приоритетных задач Росстандарта, хотя и сопряжена с рядом трудностей. В первую очередь — это создание стандартизованного алгоритма сбора и анализа данных для принятия решений в сфере государственного регулирования.

Основная часть

За последнее время опубликовано свыше 150 нормативных документов, посвященных теме искусственного интеллекта (ИИ) и машинного обучения (МО) [10]. В соответствии с одним из этих документов [11] МО характеризуют как процесс, позволяющий научить вычислительные системы получать знания из данных без необходимости явного программирования для реализации сложных задач, например, обнаружение характеристик. Методы МО включают использование нейронных сетей и глубокого обучения [12].

В последние годы МО стало одним из ключевых технологий, трансформирующих различные области науки и промышленности [13–15]. Машинное обучение находит применение в научной сфере, например, в астрофизике для анализа космических данных, в биологии и генетике — для предсказания структуры белков и интерпретации геномных последовательностей, а также в когнитивных науках — для исследования механизмов обработки языка и мышления. В промышленности МО играет важную роль в цифровой трансформации таких секторов, как производство (предиктивное обслуживание, автоматизация контроля качества), финансы (обнаружение мошенничества, алгоритмическая торговля), логистика и транспорт (автономные системы, оптимизация маршрутов), энергетика (интерпретация геофизических данных), безопасность (биометрическая идентификация, анализ угроз) и медиаиндустрия (генерация контента, рекомендательные системы) [16,17]. Их эффективность обусловлена способностью обрабатывать большие объёмы сложных данных, выявлять неочевидные закономерности и обеспечивать высокую скорость принятия решений, что делает их незаменимыми инструментами в условиях роста информации-

онной сложности и требований к автоматизации процессов. Для наглядности применения МО по ключевым сферам науки и промышленности на рис. 1 приведена диаграмма уровней интенсивности применения МО.

Обратимся к задаче автоматизации процесса измерения времени истечения жидкости при поверке вискозиметров. Большая часть вискозиметров стеклянных капиллярных поверяются в соответствии с типовой методикой поверки МИ 1748-87 «ГСИ. Вискозиметры стеклянные капиллярные» [18], которая диктует реализацию следующих этапов:

1. Вискозиметр заполняют градуировочной жидкостью.
2. Вискозиметр с градуировочной жидкостью помещают в термостат и выдерживают не менее 30 минут. Вертикальность проверяют по отвесу в двух взаимно перпендикулярных плоскостях. При помощи термометра контролируют температуру теплоносителя.
3. По завершении термостатирования градуировочной жидкости, оператор, используя, вспомогательное оборудование, образует в капиллярном вискозиметре так называемый «висячий уровень».
4. Оператор проводит серию измерений времени истечения определенного объема градуировочной жидкости через капилляр вискозиметра путем наблюдения и запуска/остановки секундоме-



Рис. 1. Уровень интенсивности применения МО по отраслям (оценка в баллах от 1 до 5)

ра в момент времени пересечения мениском жидкости рисунок, нанесенных на капилляр.

На этапе измерения времени истечения жидкости, ключевым моментом является формирование сигналов о начале и окончания процесса истечения контролируемой жидкости, что зачастую связано с человеческим фактором, влияющим на результаты проверки. Целесообразным представляется автоматизация именно данного этапа, в том числе, посредством применения считывающих устройств и создания базы данных, содержащей необходимую информацию для анализа данных.

В свою очередь, первый шаг измерения времени истечения жидкости представляется как задача распознавания рисок (меток), нанесенных на измерительную трубку вискозиметра. Исходными данными для задачи распознавания является набор изображений вискозиметров с различными типами и расположениями меток, которые должны быть предварительно обработаны: отфильтрованы шумы, выделены области, содержащие метки. Кроме того, каждый образец должен быть размечен — указано точное местоположение и порядковый номер каждой риски (такая необходимость трактуется алгоритмами машинного обучения) [19]. Дополнительной задачей является поиск «правильной части метки», так как изображение риски на трубке из линии, которую наблюдает оператор, превращается в эллипс (эффект параллакса) из-за угла обзора (рис. 2). Таким образом, имеется подзадача определения большой оси эллипса для выделения базовой точки отсчёта, которая станет одним из признаков при реализации алгоритмов машинного обучения.

В соответствии с терминологией, машинное обучение можно представить как процесс решения некоторой задачи двумя этапами: формирование набора данных и алгоритмическое построение на его основе статистической модели. Поставленная выше задача по распознаванию образов при реализации этапа проверки — измерении времени истечения жидкости, может состоять из двух последовательных задач кластеризации — «без обучения» и «с обучением».




Рис. 2. Эффект параллакса

Задача классификации «без обучения» направлена на создание модели на основе неразмеченных образов, где входом является некоторый вектор X , преобразованный на выходе в вектор Y , позволяющей определить принадлежность к определенной группе вискозиметров — например, в начальный и конечный моменты времени истечения жидкости. В задачах классификации построенная модель возвращает идентификатор (номер) кластера для каждого вектора признаков в наборе данных. Решение задач кластеризации базируются на специальных методах многомерной классификации, основанных на разбиении совокупности объектов исследования на сравнительно небольшое число однородных групп [19]. Реализация данных подходов осуществляется введением некоторой величины, характеризующей различие (схожесть) между объектами — расстояние (мера схожести). И объекты, характеризующиеся минимальным значением расстояния (наибольшей мерой схожести) считаются однородными и принадлежащими одному классу.

Таким образом, результат работы алгоритма «без обучения», может стать основой для реализации алгоритма «с обучением», который, в свою очередь, подразумевает наличие данных, организованных как коллекция размеченных образцов. Каждый образ представляется вектором признаков, в котором каждое измерение $j = 1, \dots, n$ содержит значение, описывающее некоторую характеристику образца. Обращаясь к нашей задаче – если каждое из исходных данных представляет собой изображение вискозиметра, тогда первым признаком, $x(1)$ на рис. 2, могла бы быть длина большой полуоси эллипса, вторым признаком, $x(2)$ – средняя линия эллипса. Для всех данных в наборе данных, признак в позиции j в векторе признаков всегда описывает одну и ту же характеристику. Метка y_i может быть элементом конечного множества классов $\{1, 2, \dots, C\}$, вещественным числом или вектором, матрицей или графом.

В качестве инструментов для решения поставленной задачи, могут выступить современные пакеты машинного обучения, написанные на языке Python, такие как TensorFlow и Keras (библиотеки, используемые для создания многослойных нейронных сетей для распознавания голоса или картинок и приложений для работы с текстом), «Scipy» (инструмент для анализа данных), «PyTorch» (инструментарий, упрощающий работу с алгоритмами машинного обучения), «NumPy» (инструмент для работы с математическими данными) и «Pandas» (инструмент для работы с большими данными).

Заключение

Таким образом, предложенный подход, основанный на последовательном применении алгоритмов машинного обучения, может стать важнейшей составляющей при создании автоматизированного комплекса, главной задачей которого является снижение ошибок, связанных с человеческим фактором при реализации этапов поверки вискозиметров стеклянных эталонных.

Библиография

1. Федеральный закон «Об обеспечении единства измерений» от 26.06.2008 № 102-ФЗ.
2. Указ Президента Российской Федерации от 20 мая 2004 г. № 649 «Вопросы структуры федеральных органов исполнительной власти» // Собрание законодательства РФ. – 2004. – № 21. – Ст. 2077.
3. Новый прибор для квантовой метрологии // За Науку : сайт. URL: <https://zanauku.mipt.ru/2020/05/29/novyy-pribor-dlya-kvantovoj-metrologii> (дата обращения: 06.05.2025).
4. Болотов С. Глава Росстандарта объяснил, как решить проблемы с качеством товаров и услуг // Российская газета : сайт. URL: <https://rg.ru/turbopages.org/rg.ru/s/2025/01/06/glava-rosstandarta-obiasnil-kak-reshit-problemy-s-kachestvom-tovarov-i-uslug.html> (дата обращения: 06.05.2025).
5. Sascha Eichstädt, Anke Keidel, Julia Tesch. Metrology for the digital age, <https://doi.org/10.1016/j.measen.2021.100232>.
6. Eichstädt, S. Metrology for the digital transformation of the economy and society, DOI: 10.7795/120.20210223
7. Loreficea S. The Italian primary kinematic viscosity standard: The viscosity scale, DOI: <https://doi.org/10.1016/j.measurement.2017.08.006>.
8. Lee S. H., Rauch Ju., Nam H. S., Yoon B. Ro., Kang W., Kwon S. Bilateral comparison between viscosity measurement standard systems developed by KRISS and PTB, DOI: <https://doi.org/10.1016/j.measurement.2023.113143>.
9. Данилов А. А. Экономические вопросы автоматизации поверки средств измерений, DOI: 10.32446/2782-5418.2024-3-30-34.
10. Стандарты по направлению «Искусственный интеллект» // Официальный сайт Росстандарта : сайт. URL: <https://www.rst.gov.ru/portal/gost/home/standarts/aistandarts> (дата обращения: 06.05.2025).
11. ПНСТ 943-2024. Искусственный интеллект. Структура архитектуры систем машинного обучения в будущих сетях, включая ИМТ-2020 : дата введения 2024-01-01. URL: <https://protect.gost.ru/default.aspx/document1.aspx?control=31&baseC=6&page=9&month=11&year=2024&search=&id=263923> (дата обращения: 06.05.2025).
12. ПНСТ 838-2023. Искусственный интеллект. Структура описания систем искусственного интеллекта, использующих машинное обучение : дата введения 2023-01-01. URL: <https://protect.gost.ru/document1.aspx?control=31&baseC=6&page=3&month=12&year=2023&search=&id=256443> (дата обращения: 06.05.2025).
13. Будкин Ю. В., Сергеичев И. В., Карамов Р. И. Применение методов машинного обучения для повышения точности оценки свойств материалов по результатам косвенных измерений // Информационно-эконо-

мические аспекты стандартизации и технического регулирования. 2023. № 3–4 (73). С. 27–32.

14. **Макушин М., Мартынов.** Некоторые проблемы современной метрологии в микроэлектронике, DOI: 10.22184/1992-4178.2020.193.2.80.91

15. **Михейкина Л. А.** Оценка цифрового потенциала субъектов Российской Федерации в области подготовки и привлечения кадров по направлению ИТ, DOI: 10.15838/ptd.2023.1.123.7

16. Искусственный интеллект в производственной сфере // TAdviser : сайт. URL: https://www.tadviser.ru/index.php/%D0%A1%D1%82%D0%B0%D1%82%D1%8C%D1%8F:%D0%98%D1%81%D0%BA%D1%83%D1%81%D1%81%D1%82%D0%B2%D0%B5%D0%BD%D0%BD%D1%8B%D0%B9_%D0%B8%D0%BD%D1%82%D0%B5%D0%BB%D0%BB%D0%B5%D0%BA%D1%82_%D0%B2_%D0%BF%D1%80%D0%BE%D0%B8%D0%B7%D0%B2%D0%BE%D0%B4%D1%81%D1%82%D0%B2%D0%B5%D0%BD%D0%BD%D0%BE%D0%B9_%D1%81%D1%84%D0%B5%D1%80%D0%B5 (дата обращения: 06.05.2025).

17. Нейросети в пищевой промышленности: открытие новых горизонтов инноваций и эффективности // FoodSMI: сайт. URL: <https://foodsmi.com/statistika-i-issledovaniya-/neyroseti-v-pishchevoy-promyshlennosti-otkrytie-novykh-gorizontov-innovatsiy-i-effektivnosti/> (дата обращения: 06.05.2025).

18. МИ 1748-87 Методические указания. Государственная система обеспечения единства измерений. Вискозиметры стеклянные капиллярные. Методика поверки : дата введения 1988-01-01 / НПО «ВНИИМ им. Д. И. Менделеева». — Ленинград : Ротапринт ВНИИМ, 1987. — 22 с.

19. Методы интеллектуального анализа данных. Задача классификации: учебное пособие / О. С. Чудинова, Р. М. Безбородникова, Е. Н. Корнейченко, А. В. Раменская, Л. М. Туктамышева, Н. П. Фот; Оренбургский гос. ун-т. — Оренбург : ОГУ, 2024. — 167 с.

NEURAL NETWORK MODELING IN THE SYSTEM OF MEASUREMENT UNIFORMITY ASSURANCE

Anastasia V. Mirgorodskaya^{1,a}, Nataliia P. Fot^{2,b}

¹D. I. Mendeleyev Institute for Metrology, St. Petersburg, Russia,

²Orenburg State University, Orenburg, Russia

^aa.v.mirgorodskaya@vniim.ru, ^bfotnp@mail.ru

Abstract. The article explores the possibility of constructing neural network models based on machine learning algorithms in metrology, aimed at automating the process of measuring liquid flow time during the calibration of glass capillary vis-

cometers. Emphasis is placed on the importance of digital transformation in ensuring measurement uniformity. An approach is proposed that relies on the use of reading devices and the automatic generation of a database, with further data processing capabilities to support decision-making. The stages of data preparation are described, including mark recognition on the viscometer and parallax correction, as well as the applicability of both supervised and unsupervised machine learning methods. Implementation of this approach will reduce the influence of human factors and align with modern requirements for digitalization and automation in metrology.

Keywords. Machine learning, clustering, digital metrology, measurement automation, pattern recognition, image processing.

* * *

УДК 330.1

doi:10.18720/SPBPU/2/id25-518

ПРЕОБРАЗОВАНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ В КОД ДЛЯ МИКРОКОНТРОЛЛЕРА И ВАЛИДАЦИЯ В МОДЕЛЬНОМ ОКРУЖЕНИИ НА РОССИЙСКОЙ ПЛАТФОРМЕ ENGEE

Капырин Николай Игоревич¹, Архипов Никита Сергеевич²,
Загорный Сергей Геннадьевич³

ЦИТМ Экспонента, Москва Россия

¹nikolay.kapyrin@exponenta.ru, ²nikita.arkhipov@exponenta.ru,

³sergey.zagorniy@exponenta.ru

Аннотация. В статье изложен способ генерации встраиваемого, платформо-независимого кода из небольших нейросетей, которые иногда используются в качестве алгоритмических решений в промышленном оборудовании. Обсуждается роль нейросетей в проектировании систем управления и промышленного мониторинга, а также необходимость проверки их в модельном окружении на ранних этапах проектирования.

Ключевые слова. Модельно-ориентированное проектирование, применения нейросетей, синтез систем управления, Engee.

Введение

Перенос нейросетей на недорогие промышленные вычислительные платформы, таких как микроконтроллеры STM32 или

МК, становится все более востребованным в современных системах автоматизации и управления.

Микроконтроллеры представляют собой экономичное решение для аппаратного воплощения алгоритмов на основе ИИ и их встраивания непосредственно в промышленное оборудование, уменьшая зависимость от централизованных вычислительных ресурсов. А ведение разработки в отечественной системе Engage [1, 2] позволяет разработчикам и вузам укреплять свою экспертизу, оставаясь в легальном поле и сохраняя возможность гибкой поставки и развертки данного ПО, пользования техподдержкой и максимально простого переноса проектов из MATLAB при помощи этого браузерного решения.

В статье рассматривается, как при помощи Engage, языка Julia и библиотеки Symbolics автоматизировать преобразование в код для микроконтроллеров различных нейросетей, разработанных во Flux, и как тестировать полученные алгоритмы в окружении для модельно-ориентированного проектирования [3].

Мотивация к использованию языка Julia в разработке нейросетей

Выбор языка Julia в качестве основы для предложенной методологии обусловлен его уникальными характеристиками, особенно ценными для задач разработки и трансформации нейросетевых алгоритмов. В отличие от интерпретируемых языков, Julia сочетает высокоуровневый синтаксис, удобный для быстрого прототипирования, с производительностью компилируемых языков. Это критически важно при работе с вычислительно сложными нейросетевыми моделями. Код на Julia короткий и выразительный, а скомпилированные программы работают очень эффективно.

Преимущества Julia касаются и организации внутренней инфраструктуры этого языка. Благодаря полиморфизму и множественной диспетчеризации, реализованной в этом языке, разработка новых библиотек не влечет за собой переопределения всех

базовых методов. Особенность Julia, которую мы будем больше всего использовать в этой статье — это метапрограммирование и развитая система макросов, которые позволяют реализовывать сложные преобразования абстрактных синтаксических деревьев (AST). На этом будет основано наше решение по генерации кода на языке Си при помощи библиотеки Symbolics.jl, работающей именно с AST.

Определенно, разработка даже небольших нейросетей сразу на языках программирования встраиваемых систем (C, C++) повлекла бы за собой необходимость создания дополнительных инструментов и инфраструктуры. В пользу высокоуровневых языков говорит и повсеместное использование Python для этих задач. Но в отличие от Python, Julia демонстрирует математическую стройность синтаксиса и более простые методы для генерации кода.

Генерация кода из полносвязных нейросетей

Полносвязные нейросети — хорошо изученный и устоявшийся инструмент аппроксимации алгоритмов. Создание полносвязной нейросети во Flux можно выполнить двумя строчками:

```
using Flux  
model = Dense( 1=>1, relu )
```

Первая из них запрашивает загрузку библиотеки Flux, вторая создает нейросеть с одним нейроном, имеющим один вход и один выход, на котором находится функция активации ReLU. Следующий код крайне важен для изложенного подхода генерации кода: с его помощью мы подставляем символьную переменную в абстрактный синтаксический граф нейросети.

```
using Symbolics  
@variables x  
model( [x] )
```

Благодаря богатым возможностям полиморфизма, встроенным в Engage, синтаксическое дерево преобразуется, и получаем в ответ уже не нейросеть как объект языка программирования, а констук-

цию для символьных вычислений: `[ifelse((-0.85796064x<0),0,-0.85796064x)]`. Это реализация кода нейросети на языке Symbolics. Мы видим, что функция активации ReLU, вполне ожидаемо, породила кусочно-линейное описание нейрона.

Назначим параметрам нейросети некоторые наглядные значения:

```
model.weight .= [10]
```

```
model.bias .= [20]
```

Последний этап нашего подхода — генерация кода через функцию `build_function()` библиотеки Symbolics:

```
c_model_code = build_function( model( [x] ), [x]; target=Symbolics.CTarget(), fname="neural_net", lhsname=:y, rhsnames=[:x] )
```

В результате мы получаем вполне валидный код на Си:

```
#include <math.h>
```

```
void neural_net(double* y, const double* x) {
```

```
y[0] = ifelse(20.0f0 + 10.0f0 * x[0] < 0, 0, 20.0f0 + 10.0f0 * x[0]); }
```

В зависимости от стандарта и реализации, в языке Си для целевой платформы может не быть оператора `ifelse` или может не быть поддержки типа `double`, но эти отклонения можно исправить либо полнотекстовой подстановкой, либо настройкой шаблона кодогенерации.

Генерация кода из рекуррентных нейросетей

Есть много других стандартных формализмов нейросетей (сети Больцмана, Хопфильда, автоэнкодеры, рекуррентные и сверточные нейросети, трансформеры и т. д.). Многие из этих топологий либо не встречаются в промышленности, либо не требуют разработки, так как поставляются в заведомо предобученном виде (например, трансформеры сразу на языке Си, например как это сделано в [4]).

Сверточные и рекуррентные сети встречаются достаточно часто, поэтому рассмотрим один из этих двух вариантов. Рекуррентные сети могут быть многослойными, но отличаются топологией нейронов, в которых предусмотрен дополнительный вектор “входных” переменных — скрытое состояние. Если мы

зададимся целью создать нейросеть с двумя входными каналами и тремя переменными в скрытом слое, то мы можем это сделать следующим образом:

```
input_channels_nb = 2
```

```
hidden_state_size = 3
```

```
rnn = Flux.RNNCell(input_channels_nb, hidden_state_size)
```

Выставив наглядные начальные значения `rnn.Wh`, `rnn.Wi` и `rnn.b` (соответствующие весам и смещениям) мы можем сгенерировать код следующим образом:

```
X = Symbolics.variables( :x, 1:input_channels_nb )
```

```
H = Symbolics.variables( :h, 1:hidden_state_size )
```

```
rnn_model = Flux.Recur(rnn, H)
```

```
y = rnn_model( X )
```

Объект `Recur` берет на себя работу со скрытым состоянием.

Наконец, функция `build_function()` позволит нам получить код нейросети на Си:

```
c_model_code = build_function( rnn_model( X ), [X; H]; target=Symbolics.CTarget(), fname="neural_net", lhsname=:LHS, rhsnames=[:RHS] )
```

В результате мы получим следующий код:

```
#include <math.h>
```

```
void neural_net(double* LHS, const double* RHS) {
```

```
LHS[0] = tanh(0.002f0 + 0.02f0 * RHS[0] + 0.05f0 * RHS[1] + 0.2f0 * tanh(0.002f0 + 0.02f0 * RHS[0] + 0.05f0 * RHS[1] + 0.2f0 * RHS[2] + 0.5f0 * RHS[3] + 0.8f0 * RHS[4]) + 0.5f0 * tanh(0.003f0 + 0.03f0 * RHS[0] + 0.06f0 * RHS[1] + 0.3f0 * RHS[2] + 0.6f0 * RHS[3] + 0.9f0 * RHS[4]) + 0.8f0 * tanh(0.004f0 + RHS[4] + 0.04f0 * RHS[0] + 0.07f0 * RHS[1] + 0.4f0 * RHS[2] + 0.7f0 * RHS[3]));
```

```
LHS[1] = tanh(0.003f0...
```

Отметим, что в коде встречается функция активации `tanh`, которую мы задали в описании нейросети. Как правило, после такой нейросети будет находиться полносвязанный слой для проекции латентного представления в полезную выходную переменную. Благодаря векторизации многих блоков Engage позволит нам работать как в одной, так и с несколькими выходными переменными




Рис. 1. Типичная модель с нейросетью на языке C в Engage

этой нейросети, или даже с матрицами для целого батча. Многие действия в Engage (например, манипуляции с латентными состояниями) можно выполнить совсем без программирования, пользуясь только инструментами графического моделирования, как это показано на рис. 1.

На рис. 2 представлена настройка блока C Function для работы с векторными данными.

Как видно из демонстрации, на данном этапе вполне можно утверждать, что язык Julia отлично подходит для генерации кода из нейросетей. Это метод генерации легко масштабировать и автоматизировать, а полученные алгоритмы легко перенести в модельное окружение и начать тестировать задолго до того, как целевая платформа будет готова для потенциально опасных испытаний.

Генератор кода Symbolics поддерживает преобразование AST нейросети в код на C или на Julia. Оба эти языка программирования в Engage снабжены инструментами, позволяющими размещать алгоритмы на графической модели. Пример отладочного стенда представлен на рис. 3.

Технология генерации кода и этап валидации в модельном окружении позволяют исключить сопутствующую ручному кодированию потерю функциональных возможностей или иного несогласования реализации с техническим заданием.




Рис. 2. Настройка блока C Function для работы с векторными данными




Рис. 3. Огладный стэнд с нейронным регулятором в Engage

Заключение

Проведенное исследование демонстрирует эффективный метод трансформации нейросетевых моделей, разработанных в среде Flux.jl, в оптимизированный C-код для микроконтроллерных платформ с использованием возможностей языка Julia и библиотеки Symbolics.jl. Предложенный подход существенно сокращает цикл разработки встраиваемых интеллектуальных систем, обеспечивая формализацию процесса создания сложных современных аппаратных устройств.

Можно отметить существенное снижение входного порога и открытость Engage к интеграции с другими отечественными платформами, а также возможности тестирования полученных решений в современном модельном окружении, где доступны конечные автоматы, физическое моделирование и обычные алгоритмические инструменты моделирования.

Реализация данного проекта в среде Engage подтверждает применимость изложенного подхода и его полезность в разработке отечественных цепочек инструментов для автоматизации сложных промышленных задач, такие как внедрение нейросетей, создание цифровых двойников или предиктивная аналитика.

Библиография

1. Портал компании ЦИТМ Экспонента // Главная страница портала URL: <https://exponenta.ru/> (дата обращения: 01.06.2024).
2. Российская среда динамического моделирования Engage // Личный кабинет пользователя Engage URL: <https://www.engage.com> (дата обращения: 01.06.2024).
3. Модельно-ориентированное проектирование. Систематическое использование моделей во всех процессах разработки // Сайт компании MathWorks URL: <https://www.mathworks.com/solutions/model-based-design.html> (дата обращения: 01.06.2024).
4. STMicroelectronics – STM32 model zoo [Электронный ресурс]. 2025. URL: <https://github.com/STMicroelectronics/stm32ai-modelzoo> (Дата обращения 10.05.2025);

TRANSFORMING NEURAL NETWORK ALGORITHMS INTO MICROCONTROLLER CODE WITH SIMULATION- BASED VALIDATION USING THE RUSSIAN ENGINEERING PLATFORM ENGEE

Nikolay I. Kapyrin¹, Nikita S. Arkhipov², Sergei G. Zagorniy³

ETCM Exponenta, Moscow, Russia

¹nikolay.kapyrin@exponenta.ru, ²nikita.arkhipov@exponenta.ru,

³sergey.zagorniy@exponenta.ru

Abstract. The article presents a method for generating embeddable, platform-independent code from small neural networks, which are sometimes found as temporary algorithmic solutions in industrial equipment. The role of neural networks in control system design and industrial monitoring is discussed, along with the need to test them in a simulated environment during the early stages of development.

Keywords. Model-based development, multi-domain systems, neural network management, control synthesis, Engee.

* * *

УДК 004.032.26:006.05

doi:10.18720/SPBPU/2/id25-519

АВТОМАТИЗАЦИЯ МЕТРОЛОГИЧЕСКОЙ ЭКСПЕРТИЗЫ СТАНДАРТОВ С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ: АРХИТЕКТУРА, ФУНКЦИОНАЛЬНОСТЬ И ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ

Аминова Анастасия Сергеевна^{1,а}, Аверич Владимир Евгениевич^{2,б},
Овсянников Кирилл Александрович^{2,в}

¹ВНИИМ им. Д. И. Менделеева, Санкт-Петербург, Россия,

²Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

^аnast781826@gmail.com, ^бvaverich3@inbox.ru, ^вovsyannikov.ka@edu.spbstu.ru

Аннотация. В статье рассматривается разработка веб-сайта, использующего нейронную сеть для автоматизации метрологической экспертизы

проектов национальных стандартов. Актуальность исследования обусловлена необходимостью повышения точности, согласованности и оперативности подготовки нормативных документов. Выдвинутое решение предусматривает анализ и оценку содержания проектов стандартов, выявление ошибок и несоответствий, а также формирование рекомендаций по их устранению. В работе представлена микросервисная архитектура с использованием языков программирования Python и Go, а также семантического анализа, графовых и векторных моделей. Исследование ориентировано на формирование единого информационного пространства для всех участников процесса разработки стандартов.

Ключевые слова. Метрологическая экспертиза, автоматизация, нейронная сеть, стандартизация, проекты национальных стандартов, веб-сайт, архитектура

Введение

По результатам метрологической экспертизы проектов стандартов прослеживаются характерные замечания и предложения по построению, изложению и оформлению проектов стандартов. Согласно [10] в качестве меры по их предотвращению предлагается совершенствовать процедуру метрологической экспертизы.

В исследовании [1] представлены основные виды несоответствий, с которыми сталкиваются эксперты во время проведения метрологической экспертизы проектов стандартов. Для решения этой проблемы предлагается разработка экспертной системы на основе нейронной сети для выпуска качественной документации.

В это же время других исследователей также интересовали модернизация и развитие стандартизации с использованием технологий искусственного интеллекта. На момент выпуска статьи ведутся работы по цифровой трансформации национальной системы стандартизации с использованием искусственного интеллекта. Автор исследования [3] описывает ключевые цели внедрения цифровых технологий в процедуры разработки документов по стандартизации для электронного взаимодействия разработчиков, технических комитетов, а также специалистов по стандартизации и качеству на предприятиях. Генеральный директор ФГБУ «Российский институт стандартизации» (ФГБУ «РСТ») Миронов Д. Е.

в интервью рассказывает какие на данный момент ведутся работы в этом направлении: разработка машиночитаемых и машинопо-нимаемых документов, создание подсистемы Федеральной госу-дарственной информационной системы Росстандарта («Береста 2.0») [9]. Более подробно говорится о едином информационном пространстве для разработки документов на этапах рассмотрения, обсуждения, голосования и утверждения в статье [7]. Экосистема «Береста 2.0» также должна включать в себя сервис «Конструктор документов» для формирования первой редакции проекта доку-мента с функцией автоматической проверки [8]. В другой системе управления нормативными техническими документами (СУ НТД) «Техэксперт» реализована подсистема «Обсуждение нормативных документов» для совместной разработки документов и взаимо-действия сотрудников на предприятии, а в СУ НТД «Техэксперт SMART» подсистема «Конструктор нормативных документов» для оформления, разметки и автоматической привязки замечаний к разным частям текста документа [2].

Предложенные решения упростят разработку документов в обла-сти стандартизации, однако не все подсистемы на данный мо-мент реализованы и невозможно оценить насколько они полезны и удобны для пользователя. Доступ к использованию подсистем предоставлен не всем предприятиям и организациям.

Параллельно с создаваемыми платформами, упомянутыми выше, авторами настоящего исследования ведется разработка веб-сайта, который использует нейронную сеть для автоматизации процесса метрологической экспертизы проектов стандартов. Это позволит выявлять в проектах национальных стандартов ошибки и несоответствия, а затем предлагать решения по их устранению разработчику.

Перспективы разработки веб-сайта

После подготовки разработчиком первой редакции проекта на-ционального стандарта документ проходит несколько этапов. Про-цесс начинается с приема и проверки первой редакции проекта

стандарта секретариатом технического комитета (ТК) на соответ-ствие положениям 4.3.1 и 4.3.2 стандарта [5], а также требованиям разделов 3 и 4 стандарта [6]. Срок проверки не должен превышать 10 дней. После этого первая редакция проекта стандарта разме-щается на сайте ТК для публичного обсуждения членами ТК и за-интересованными лицами. Тем не менее, часто на практике при обсуждении и составлении отзыва на проект стандарта выявляется много несоответствий в соблюдении указанных выше положений. Из этого следует, что секретариат ТК только ведет прием и рассыл-ку документов, а не проводит контроль на соответствие требова-ниям основополагающих документов.

В разработке национальных стандартов участвуют не только раз-работчики проекта, но и члены ТК, заинтересованные лица и экс-перты. Весь процесс занимает длительное время и привлекает мно-гих людей. На рис. 1 представлены этапы разработки и утверждения национальных стандартов и их примерные сроки после завершения публичного обсуждения первой редакции проекта стандарта.

Крайне необходимо для всех участников процесса разработки национального стандарта сосредоточиться на содержании проекта




Рис. 1. Примерные сроки этапов по разработке и утверждению проекта национального стандарта

стандарта, а не отвлекаться на несоответствия в структуре документа, затрачивая много времени.

Разрабатываемая нейронная сеть снизит нагрузку на участников разработки, минимизирует количество ошибок и несоответствий, а также оптимизирует сроки прохождения всех этапов согласования. Ниже приведены ключевые преимущества предлагаемого решения:

- разработчики могут сосредоточиться на содержании проекта стандарта, несоответствия в форматировании не отвлекают разработчика от предметных обсуждений;
- разработка проекта стандарта занимает меньше времени, тем самым оптимизируя процесс разработки;
- предложенный подход способствует достижению консенсуса в ТК после голосования;
- процесс разработки проекта стандарта проходит на одной платформе, что исключает рассинхронизацию версий проектов стандартов после значительных коррекций.

Интерфейс веб-сайта

Основными пользователями веб-сайта будут разработчики проектов национальных стандартов, а также эксперты, готовящие отзывы и проводящие метрологическую экспертизу. Для работы с сайтом необходимо ввести логин и пароль для авторизации (регистрация пользователя). Интерфейс веб-сайта состоит из следующих блоков (рис. 2):

- свойства документа (данные о разработчике, наименование проекта стандарта и его шифр ПНС);
- структура документа (количество страниц; на каких страницах и какую долю документа занимают разделы в тексте проекта стандарта);
- текстовые метрики (доля научной лексики; обороты разговорной лексики, техницизмы, профессионализмы; доля дублирующих положений; оценка связности текста);
- параметры экспертизы (начало и длительность проверки; процент оригинальности и цитирования);




Рис. 2. Интерфейс веб-сайта

- размер документа (свойства документа).

Задачи, которые должна выполнять разработанная нейронная сеть:

- проверка соответствия оформления и изложения проекта стандарта требованиям [6] и [4];
- поиск орфографических, пунктуационных и иных ошибок в тексте проекта стандарта;
- поиск в тексте проекта стандарта требований/положений, которые частично или полностью дублируют требования/положения других документов в области стандартизации, по этой же или смежной тематике;
- оценивание соответствия норм точности, рекомендуемых средств измерений, условий их применения, состава измеряемых параметров и других сведений, приведенных в проекте стандарта, требованиям взаимосвязанных стандартов;
- контроль соответствия показателей качества и норм безопасности, приведенных в проекте стандарта, Федеральным законам, действующим стандартам, приказам Росстандарта;
- оценивание соответствия терминологии, использованной в проекте стандарта, терминологии действующих стандартов для выявления и устранения искажения определений;
- оценивание соответствия содержания основного текста проекта стандарта наименованию проекта стандарта;
- введение возможности контролируемого дообучения нейронной сети с целью расширения области ее применения;

— введение в нейронную сеть возможности автоматической или ручной коррекции документации, которая была подвергнута метрологической экспертизе, на основе ошибок, выявленных нейронной сетью, путем принятия решений пользователем.

Архитектурные решения и их обоснование

Выбор микросервисной архитектуры. Разрабатываемая система построена на основе микросервисной архитектуры и обеспечивает единый подход к оформлению документов по стандартизации с перспективой интеграции искусственного интеллекта для семантического анализа содержимого.

Принятие решения об использовании микросервисной архитектуры обусловлено рядом ключевых факторов, характерных для данной предметной области. К ним относятся следующие:

- разделение ответственности по функциональным доменам: управление пользователями и профилями, хранение и управление документами, а также специализированная обработка документов;

- технологическая гетерогенность — различные компоненты системы имеют принципиально разные требования к производительности и функциональности.

Сервис обработки документов требует богатых библиотек для работы с форматами Office, что делает Python оптимальным выбором благодаря таким инструментам как `python-docx`. В то же время сервисы профилей и хранения документов ориентированы на высокую производительность и конкурентность, что обосновывает использование Go с его эффективной моделью `goroutines` и встроенной поддержкой HTTP/2. При этом важно учесть масштабируемость и отказоустойчивость — в контексте обработки больших объемов документов критически важна возможность независимо масштабирования компонентов.

Технологический стек и его обоснование. Backend-сервисы на языке Go выбраны для компонентов, требующих высокой производительности при работе с `concurrent` запросами. Статическая

типизация и компиляция в нативный код критически важны для production-ready решений в enterprise-среде.

Выбор языка Python для сервиса обработки документов обусловлен наличием специализированных библиотек для работы с форматом DOCX и возможностью интеграции с ML-моделями для будущего семантического анализа. Фреймворк Flask обеспечивает быстрое прототипирование и развертывание REST API с минимальными накладными расходами.

PostgreSQL как основное хранилище выбран, поскольку позволяет обеспечить превосходную поддержку ACID-транзакций, расширенных индексов (включая полнотекстовый поиск для метаданных документов) и возможности хранения JSON-структур для гибких пользовательских профилей.

MinIO для объектного хранения представляет собой S3-совместимое решение, позволяющее эффективно управлять версионированием документов, обеспечивать распределение данных.

Межсервисное взаимодействие и паттерны надежности. Выбор REST API обусловлен его универсальностью и простотой отладки, что критически важно на этапе активной разработки. HTTP/JSON обеспечивает прозрачность взаимодействия и упрощает мониторинг системы.

Использование Docker и Docker Compose обеспечивает консистентность сред разработки и production, что критически важно для системы с гетерогенным технологическим стеком. Каждый микросервис упаковывается в отдельный контейнер с минимальным базовым образом, что снижает поверхность атак и ускоряет развертывание.

Интеграция с нейронной сетью. Архитектура системы изначально проектируется с учетом интеграции специализированных AI-модулей по четырем ключевым направлениям. Выбор Python в качестве основы для сервиса обработки документов обусловлен не только наличием библиотек для работы с DOCX, но и богатой экосистемой машинного обучения.

Система будет детектировать дублирование стандартов через семантическое сравнение на основе векторных моделей, обучен-

ных на документах по стандартизации. Каждый раздел документа преобразуется в вектор и сравнивается с базой стандартов с использованием FAISS для быстрого поиска. Иерархическая проверка выявит полные совпадения, копирование разделов или отдельных формулировок, а временной анализ с применением графовых нейронных сетей учтёт версию документов, отличая оригинальный документ от плагиата.

Правовая валидация будет проводиться моделью, обученной на документах в области стандартизации, которая проверит соответствие документа через извлечение ссылок (NER) и оценку соответствия (compliance scoring). Терминологическая корректность обеспечится графовой моделью и дообученным LLM для контекстного анализа, а проверка смысловой целостности выявит логические несоответствия. Система будет автоматизировать метрологическую экспертизу документов с возможностью ручного контроля и постоянного дообучения.

Заключение

Проведённое исследование демонстрирует высокий потенциал применения нейронных сетей для автоматизации процессов метрологической экспертизы проектов национальных стандартов. Разработка направлена на снижение нагрузки на участников разработки, повышение качества документации и сокращение сроков прохождения процедур согласования.

Выбор микросервисной архитектуры, современных инструментов хранения и обработки данных, а также реализация специализированного интерфейса для экспертов и разработчиков способствует созданию устойчивой, масштабируемой и эффективной платформы.

Организация единого пространства для взаимодействия всех участников процесса разработки национальных стандартов является важным шагом на пути цифровой трансформации национальной системы стандартизации и подтверждает актуальность применения технологий искусственного интеллекта.

Библиография

1. Аминова А. С. Метрологическая экспертиза проектов стандартов: перспектива разработки нейронной сети для автоматизации процесса // Прикладной искусственный интеллект: перспективы и риски: Международная научная конференция: сб. докл. — СПб.: ГУАП. — 2024. — С. 10–14.
2. **Артемяева В. Р. Самотуго И. С.** Как обуздать стихию: автоматизация коллективной работы над документом // Стандарты и качество. — 2025. — № 5 (1055). — С. 42–45.
3. **Будкин Ю. В.** Цифровизация в стандартизации // Стандарты и качество. — 2024. — № 5 (1043). — С. 38–39.
4. ГОСТ 1.5 Межгосударственная система стандартизации (МГСС). Стандарты межгосударственные, правила и рекомендации по межгосударственной стандартизации. Общие требования к построению, изложению, оформлению, содержанию и обозначению.
5. ГОСТ Р 1.2-2020 Стандартизация в Российской Федерации. Стандарты национальные Российской Федерации. Правила разработки, утверждения, обновления, внесения поправок и отмены.
6. ГОСТ Р 1.5 Стандартизация в Российской Федерации. Стандарты национальные. Правила построения, изложения, оформления и обозначения.
7. **Миронов Д. Е.** Основные направления цифровой трансформации стандартизации. Часть 3 // Стандарты и качество. — 2024. — № 5 (1043). — С. 34–36.
8. **Миронов Д. Е.** Основные направления цифровой трансформации стандартизации. Часть 2 // Стандарты и качество. — 2024. — № 4 (1042). — С. 58–61.
9. **Миронов Д. Е.** Российская стандартизация — основа технологического суверенитета // Business Excellence. — 2024. — № 10. — С. 15–21.
10. РМГ 63 Государственная система обеспечения единства измерений. Обеспечение эффективности измерений при управлении технологическими процессами. Метрологическая экспертиза технической документации.

AUTOMATIZATION OF METROLOGICAL EXPERTISE OF STANDARDS USING NEURAL NETWORKS: ARCHITECTURE, FUNCTIONALITY AND IMPLEMENTATION PERSPECTIVES

Anastasia S. Aminova¹, Vladimir E. Averich², Kirill A. Ovsyannikov³

¹D. I. Mendeleev Institute for Metrology, Saint-Petersburg, Russia,

²Peter the Great St. Petersburg Polytechnic University,
Saint-Petersburg, Russia

^anast781826@gmail.com, ^bvaverich3@inbox.ru,

^covsyannikov.ka@edu.spbstu.ru

Abstract. The article deals with the development of a website using a neural network to automate the metrological examination of draft national standards. The relevance of the study is determined by the need to improve the accuracy, consistency and efficiency of the preparation of normative documents. The proposed solution provides for the analysis and evaluation of the content of draft standards, identification of errors and inconsistencies, as well as the formation of recommendations for their elimination. The paper presents a microservice architecture using the programming languages Python and Go, as well as methods of semantic analysis, graph and vector models. The research is aimed at the formation of a unified information space for all participants of the standards development process.

Keywords. Metrological expertise, automatization, neural network, standardization, draft national standards, website, architecture.

* * *

УДК 621.89.099.6

doi:10.18720/SPBPU/2/id25-520

БЕЗРАЗБОРНАЯ РВС-ТЕХНОЛОГИЯ, КАК ОДНА ИЗ СОСТАВЛЯЮЩИХ ПРЕДПИСАТЕЛЬНОЙ НАДЕЖНОСТНО-ОРИЕНТИРОВАННОЙ СИСТЕМЫ

Кобыльсков Игорь Петрович

ООО «НПК Русспромремонт», Санкт-Петербург, Россия

kobylskov@list.ru

Аннотация. В современных реалиях актуальнейшей задачей является обеспечение работоспособности техники с оптимизацией затрат

на ее эксплуатацию, техническое обслуживание и ремонт. В статье представлена промышленная технология управления износом, позволяющая обеспечить требуемый уровень надежности работы технологических машин и соответствующая критериям наилучших доступных технологий.

Ключевые слова. Ремонтно-восстановительные составы (РВС), металло-керамический защитный слой (МКЗС), безразборная технология, «безызносность», РВС-технология.

Введение

В настоящее время в российской экономике особенно актуальными становятся проблемы, связанные с выходами из строя деталей машин и механизмов в эксплуатации. По мнению специалистов, основной причиной этой проблемы является изнашиваемость поверхностей трения [2]. В связи с этим особую значимость приобретает анализ способов повышения износостойкости взаимодействующих поверхностей трения в узлах трения механизмов с учетом технологичности и экономической эффективности.

Постановка задачи

Описание предметной области. Инженеры-исследователи Ленинградского института авиационного приборостроения, решая задачу повышения износостойкости пар трения, предложили использовать минеральные композиции. Это направление исследований было поддержано председателем Ленинградского филиала Межведомственного научного совета по трибологии при АН СССР, ГКНТ СССР и Союзе НИО СССР генеральным директором Межотраслевого научно-технического комплекса «Механобр» членом-корреспондентом АН СССР Ревнивцевым В. И., который организовал фундаментальные исследования возникновения противоизносных свойств минералов в процессе их активации.

Проведенные исследования показали, что применение специальных минеральных композиций способно изменить ход класси-

ческой кривой износа в паре трения: фиксируется компенсация произошедших износов с уменьшением и оптимизацией зазора в паре трения, снижение интенсивности изнашивания поверхностей трения с увеличением периода нормальной эксплуатации пары трения [3].

Заслуги учёных по борьбе с износом оценили в 1987 году: на ВДНХ — ЛИАП удостоили дипломом I степени, золотой медалью — Маринич Тайгету Леонидовну — старшего научного сотрудника института, разработчика геоэнергетических технологий. Используемые специальные минеральные композиции получили название ремонтно-восстановительные составы (РВС).

Определение проблемы. Существующие традиционные подходы к техническому обслуживанию и ремонту машин не удовлетворяют предъявляемым требованиям к производственным активам, поэтому ведется постоянная работа по совершенствованию используемых способов и инструментов поддержания требуемой надежности активов с оптимизацией затрат в этом направлении. Предложено апробированное решение по реализации технологии управления износом. Промышленный вариант технологии получил название «РВС-технология» и защищен патентом Российской Федерации на изобретение [4].

Решение проблемы

Особенности РВС. РВС не являются присадками к смазочным материалам, т. к. объектом воздействия являются не смазочные материалы, а поверхности пар трения в местах их контактов. Установлено, что введение РВС в смазочные материалы в рекомендованных концентрациях не вызывает изменение физико-химических показателей масел и смазок [5].

Результатом воздействия РВС на поверхности пар трения является модификация взаимодействующих поверхностей с образованием металлокерамического защитного слоя (МКЗС). Образованный МКЗС является единым целым с подложкой на уровне кристаллических структур, улучшая трибологические характери-

стики начальных поверхностей трения и частично компенсируя произошедшие износы [6].

МКЗС обладает уникальными свойствами:

- обладает меньшей шероховатостью, чем шероховатость подложки, на которой образовался;
- удерживается на поверхности значительно лучше, чем наплавки;
- обладает более высокой микротвёрдостью по сравнению с микротвёрдостью подложки;
- по мере износа слоя его можно восстанавливать, проводя дополнительные обработки РВС [7].

После применения РВС при замене смазывающих материалов в соответствии с регламентом обслуживания не требуется обязательного повторного введения РВС. РВС улучшают условия работы пар трения, выполненных из черных и цветных металлов, их сплавов и композиционных материалов [8-11]. Технология промышленного применения ремонтно-восстановительных составов получила название «РВС-технология». РВС-технология (патент РФ №2266979) — технология восстановления и улучшения характеристик машин и механизмов без вывода из эксплуатации с использованием РВС, реализующих эффекты восстановления и «безыносности» в парах трения.

Своевременное применение РВС позволяет поддерживать значения зазоров в парах трения работающих механизмов в допустимых диапазонах, обеспечивая нормальную эксплуатацию в необходимом временном интервале без аварийного износа.

Преимущества РВС-технологии. Преимущества РВС-технологии перед традиционным подходом к техническому обслуживанию и ремонту оборудования:

- применяется в режиме штатной эксплуатации оборудования без его разборки и без остановки технологических процессов;
- комплексный эффект от применения: компенсация износов в парах трения, экология, энерго— и ресурсосбережение;
- кардинальное снижение затрат: окупаемость мероприятий от 0,5 до 6 месяцев.

Результаты применения предложенного решения

Ресурсосбережение. Сотрудничество с АО «СЕВЕРСТАЛЬ» продолжается с 1998 года. В 2003 году во время выполнения производственной программы стойкость подшипников жидкостного трения (ПЖТ-1180) прокатного стана 2800 перестала удовлетворять производство: увеличилось количество брака, начались аварийные остановки.

Альтернативой предстоящим инвестиционным затратам на модернизацию стана стала НИОКР по увеличению ресурса подшипников с привлечением завода-производителя «Подшипники жидкостного трения «Электростальский завод тяжелого машиностроения» и применением ремонтно-восстановительных составов.

Итоги внедрения результатов НИОКР: ресурс увеличен более, чем в 2 раза, сокращен объем закупок, получен 10-кратный экономический эффект и патент РФ на способ подготовки к эксплуатации подшипников жидкостного трения [12]. На Светогорском целлюлозно-бумажном комбинате работы проводились в 2002 году, через 2 года эксплуатации провели анализ функционирования обработанного оборудования, имевшего наработку 13–15 тысяч моточасов.

Основные выводы [13]:

- проблемные механизмы безаварийно отработали до плановых сервисных мероприятий;
- снижены затраты на ремонт до 12 раз;
- окупаемость затрат на РВС-обработку только за счет сокращения потребления электроэнергии не более 6 месяцев (в ценах 2004 года).

С 2014 года продолжается сотрудничество по применению РВС-технологии на оборудовании золотодобывающего рудника Купол. В 2019 году произведена оценка мероприятий по РВС-технологии — зафиксирован 20-кратный экономический эффект за счет увеличения ресурса работы двигателей самосвалов для подземных работ Caterpillar CAT AD45B без учета экономии горюче-смазочных материалов и сокращения других эксплуатационных расходов [14].

Энергосбережение. Значительный энергосберегающий эффект применения РВС обеспечил включение мероприятий по РВС-технологии как нетиповых мероприятий по энергосбережению в Программы энергосбережения со сроками окупаемости от 3 до 6 месяцев. Согласно мероприятиям Программы энергосбережения ООО «НОВАТЭК-Юрхаровнефтегаз» в 2013 году были обработаны по РВС-технологии подшипниковые узлы электродвигателей. Мониторинг результатов обработки зафиксировал экономию потребления электроэнергии обработанными электродвигателями от 1,5 до 7,5 %, что позволило получить предприятию окупаемость мероприятий за 6 месяцев [15]. Анализ работы обработанного оборудования, проведенный в 2020 году, показал, что средняя наработка до отказа подшипников, обработанных по РВС-технологии превышает 40 000 часов (до применения РВС средняя наработка до отказа составляла 12 000 часов) [16].

Работы по РВС-технологии на дизель-генераторных установках «Сахаэнерго» проводились с 2008 года по рекомендациям «Центрального научно-исследовательского дизельного института» с целью сокращения затрат по программе «Ремонт основного оборудования». Дополнительным бонусом получены: снижение расхода топлива от 4 до 10 %; снижение расхода масла на угар. Мероприятия по РВС-технологии внесены в программу энергосбережения компании со сроками окупаемости 3 месяца только за счет экономии топлива, без учета сокращения логистических затрат.

Импортозамещение. Многие актуальные вопросы импортозамещения успешно решаются с использованием РВС-технологии. Опыт работы с машиностроительными заводами показывает, что применение РВС-технологии способствует повышению конкурентоспособности российских предприятий и повышению качества выпускаемой ими продукции (подшипники, редукторы, электротехническое и насосное оборудование). В области смазывающих материалов накоплен опыт замены импортных продуктов на отечественные с РВС, улучшающих надежность и эксплуатационные характеристики машин и механизмов.

В 2019 году проведены работы по РВС-технологии на дизель-генераторной установке Caterpillar 3512B. Цель работы состояла в проверке возможности перехода с импортного масла на отечественное и увеличение срока службы масла по браковочному показателю. После обработки двигатель улучшил свои эксплуатационные характеристики, что отражено в диагностических картах, а состояние масла оценивалось через интервалы 250 моточасов в аккредитованной лаборатории. Масло Rosneft Revolut D3 15W-40 оказалось годным к дальнейшей эксплуатации при наработке 1 000 моточасов, а масло Total RubiaTIR 6400 15W-40 требовало замены на наработке 250 моточасов [17].

В 2023 году на предприятии ПГ «Фосфорит», входящее в компанию ЕвроХим, во время планового технического обслуживания компрессоров Atlas Copco было залито не оригинальное масло, ввиду его отсутствия, а подобранный аналог. В результате один компрессор вышел из строя, а у второго в декабре 2023 года стали резко расти вибрационные показатели. Возник риск остановки цеха АММОФОС. Было принято решение о применении РВС-технологии для обеспечения работоспособности компрессора. В результате проведенной работы обеспечена работоспособность компрессора со снижением и стабилизацией вибрационных показателей и увеличением остаточного ресурса, мониторинг в июне 2025 года зафиксировал стабильность контрольных показателей.

Заключение

Представленная РВС-технология соответствует критериям наилучших доступных технологий и может быть использована для успешного решения целого ряда задач в достижении целей устойчивого развития предприятий промышленности, энергетики и транспорта [18].

Библиография

1. Постановление Правительства РФ от 23.12.2014 №1458 (ред. от 03.03.2021).
2. Трение, износ и смазка (трибология и триботехника) / А. В. Чичинадзе, Э.М. Берлинер, Э.Д. Браун и др.; Под общ. ред. А. В. Чичинадзе. — М.: Машиностроение, 2003. — 576 с.; ил.
3. Отчет о НИР «Изыскание возможностей использования в триботехнике руд, горных пород и минералов из отвалов месторождения с целью уменьшения износа машин и механизмов и экономии металлов», МНТК «Механообр», 1988. — 63 с.; ил.
4. Патент РФ на изобретение №2266979 «Состав для формирования новообразованного слоя на трущихся металлических поверхностях».
5. Письмо ОАО «Пермский завод смазок и СОЖ» №25/04-2012 от 01.10.2012 г.
6. Заключение о проверке эффективности РВС-технологии. Забайкальская железная дорога, 21.05.2001 г.
7. **Борозна А. А., Кобыльсков И. П., Салминен Э. О., Сизов А. Ю.** Повышение энергоэффективности и надёжности работы механизмов лесопромышленного комплекса на основе использования РВС-технологий. // Материалы 5 международной научно-технической конференции «Автоматизация и энергосбережение машиностроительного и металлургического производств, технология и надёжность машин, приборов и оборудования. Вологда, 2009, 117 — 120 с.
8. Отчет о НИР «Исследование и разработка технологий модификации пар трения в трибосистеме «рельс-колесо» с применением ремонтно-восстановительных составов», Забайкальская железная дорога, НТО «НВЦ», Забайкальский институт железнодорожного транспорта, 2002—2004 гг.
9. Отчет о НИР «Исследование влияния смазок, содержащих минеральные добавки, на скорость износа рельсов на перегонах и станциях», Забайкальская железная дорога, Забайкальский институт железнодорожного транспорта, 2003 г.
10. Акт о предварительных испытаниях влияния составов, изготовленных по РВС-технологии (патент РФ №2266979) ЗАО «НПК Русспромремонт», примененных в приработочном покрытии при испытаниях подшипникового материала СТЭТ-МФ на втулочном стенде ЛВТ филиала ОАО Силовые машины «ЛМЗ» в СПб, 2009 г.
11. Технический отчет № 51402/06-2024-03 «Результаты испытаний ремонтно-восстановительного покрытия (РВС) фирмы ООО «НПК Русспромремонт» (патент РФ №2266979) в процессе приработки антифрикционных материалов, используемых в уплотнениях валов и турбинных

подшипниках». АО «Силовые машины – ЗТЛ, ЛМЗ, Электросила, Энергомашэкспорт», Санкт-Петербург, 2024.

12. Патент РФ на изобретение №2327908 «Способ подготовки к эксплуатации подшипников жидкостного трения», ОАО «Северсталь», приоритет 23 мая 2006 г.

13. Отчет о результатах ресурсных испытаний РВС-технологии на IP ОАО «Светогорск», 2004.

14. Анализ результатов применения ремонтно-восстановительных составов (патент РФ №2266979) на технике золотодобывающего рудника «Купол», 2020.

15. Технический отчет по результатам применения РВС-технологии на подшипниках электродвигателей в рамках программы энергосбережения ООО «НОВАТЭК-Юрхаровнефтегаз», г.Новый Уренгой, 2013.

16. Отзыв о продукции. Письмо ООО «НОВАТЭК-Юрхаровнефтегаз» №5153-03,3 от 31.07.2020 г.

17. Технический отчет по РВС-обработке двигателя Caterpillar 3512B дизель-генераторной установки №2 на скважине №443 Бузулукского месторождения, 2019.

18. Декларация «Преобразование нашего мира: Повестка дня в области устойчивого развития на период до 2030 года». Резолюция ГА ООН 25.09.2015 г.

NON-DISASSEMBLED RVS TECHNOLOGY AS ONE OF THE COMPONENTS OF A PRESCRIPTIVE RELIABILITY-ORIENTED SYSTEM

Igor P. Kobylskov

NPK Russpromremont LLC, Saint Petersburg, Russia

kobylskov@list.ru

Abstract. In today's realities, the most urgent task is to ensure the operability of equipment while minimizing the costs of its operation, maintenance and repair. The article presents an industrial technology for wear control, which makes it possible to ensure the required level of reliability of technological machines and meets the criteria of the best available technologies.

Keywords. Repair and restoration compounds (RVS), metal-ceramic protective layer (MKS), non-disassembly technology, "wear-free", RVS technology.

* * *

УДК 004.817:669.002.324.25
doi:10.18720/SPBPU/2/id25-521

ПРЕДСКАЗАТЕЛЬНАЯ АНАЛИТИКА РАСХОДА ПАРА НА МЕТАЛЛУРГИЧЕСКОМ ПРОИЗВОДСТВЕ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Зуауи Поль^{1,а}, Санников Дмитрий Олегович^{2,б},
Хохловский Владимир Николаевич^{1,б}

¹Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

²АО «Кольская горно-металлургическая компания»,
г. Мончегорск, Россия

^аpaul.jean-zouaoui@mail.ru, ^бSannikovDO@kolagmk.ru,
^бhohlovskiy_vn@spbstu.ru

Аннотация. Точное прогнозирование энергопотребления критически важно в металлургической промышленности для сокращения убытков, причем прогнозирование энергопотребления представляет собой серьезную задачу из-за большого количества параметров и нелинейной динамики систем. В статье проводится оценка различных нейронных сетей для прогнозирования расхода перегретого пара в процессе металлургического производства. Были изучены сети типа Long Short-Term Memory (LSTM), Gate Recurrent Unit (GRU) и гибридная архитектура CNN-LSTM. Оценка результатов проводилась по трём показателям: Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE) и Mean Squared Error (MSE). По результатам экспериментов выяснилось, что значения показателей ошибок низкие, однако это обусловлено главным образом тем фактом, что расход пара остаётся в пределах сравнительно узкого диапазона в течение продолжительного периода времени, а не отражает реальную предсказательную способность моделей. Более подробный анализ показал ограниченную возможность моделей обнаруживать внезапные изменения расхода пара. В конце статьи рассматриваются идеи для повышения точности прогнозирования.

Ключевые слова. Предсказательная аналитика, потребление энергии, промышленный искусственный интеллект, нейронные сети.

Введение

Генерация и распределение пара выполняют важные функции в металлургии, что требует точной калибровки паровых котлов для обеспечения оптимальной производительности. Такая калибровка необходима для удовлетворения энергетических потребностей производственного процесса, одновременно предотвращая избыточную выработку энергии и минимизируя её потери. Настоящая статья посвящена прогнозированию расхода пара с применением подхода на основе нейронных сетей для различных горизонтов прогнозирования (30 минут, 180 минут и 360 минут).

Развивая интеллектуальное производство, АО «Кольская горно-металлургическая компания» (КГМК) делает акцент на принципах устойчивого развития, которое является важным фактором для современного общества. Этот подход предполагает баланс между экономическим ростом, экологической безопасностью и социальным благополучием. КГМК активно развивает промышленные экосистемы, направленные на повышение эффективности теплогенерации, снижение потерь и минимизацию воздействия на окружающую среду. Такая устойчивая модель производства запускает положительные изменения в различных сферах общественной жизни. В связи с этим компания апробирует различные стратегии для определения наиболее эффективных метрик оптимизации производственных процессов.

Анализ существующих исследований

Многочисленные исследования проводились в области прогнозирования потребления энергии, показывая значительное улучшение точности прогнозов благодаря применению методов глубокого обучения в различных секторах экономики. Эти исследования ясно демонстрируют, что модифицированные Рекуррентные Нейронные Сети (Recurrent Neural Network, RNN), такие как LSTM и GRU, хорошо справляются с задачами прогнозирования. В сфере управления зданиями I. Amalou, N. Mouhni и A. Abdali

исследовали возможности различных типов RNN для многомерного временного ряда прогнозирования энергопотребления. GRU превзошел обе сети LSTM и RNN благодаря своей способности справляться с проблемой исчезающего градиента и сниженной сложности параметров, что критично для эффективности модели при работе с большими наборами данных [1].

В электроэнергетическом секторе R. K. Agrawal, F. Muchahary и M. M. Tripathi представили, как модель LSTM-RNN может эффективно прогнозировать долгосрочную нагрузку на пять лет вперед. Модель достигла высокой точности с показателем средней относительной погрешности (Mean Average Percentage Error, MAPE) равным 6,54 % [2].

Также внимание ученых привлекли гибридные нейронные сети, позволяющие комбинировать сильные стороны разных моделей для повышения точности прогнозирования [3]. Модели CNN-LSTM показали многообещающие результаты благодаря способности CNN извлекать и фиксировать сложные признаки, тогда как LSTM успешно обрабатывают последовательные данные. N. Somu, G. Raman MR, и K. Ramamritham подчеркнули пригодность сети kCNN-LSTM для решения задач прогнозирования энергопотребления зданий благодаря ее способности изучать пространственно-временные отношения внутри данных [4]. Кроме того, потенциал сетей CNN-LSTM был также изучен в газовой промышленности в работе Z. Wenshu и др. [5]. Настоящая статья направлена на описание того, как модель CNN-LSTM может преуспеть существующие методы.

Вызовы металлургической промышленности

В течение нескольких лет горноперерабатывающие компании сталкиваются с необходимостью обрабатывать более сложные руды по качеству и составу, поэтому обогащательные фабрики становятся всё более и более технологичными. Энергетические расходы являются значительной статьёй затрат для технологических операций, и наблюдается растущее стремление переходить на бо-

лее устойчивые и возобновляемые источники энергии. Этот последний момент усиливается экологическим законодательством и общественным вниманием к вопросам охраны окружающей среды.

Все эти вызовы сопровождаются также ростом спроса, что требует повышения эффективности и оптимизации процессов. Amit Kumar Mishra подробно рассматривает эти вызовы и способы их преодоления с помощью ИИ в обзоре “A Review of the Applications of AI in Mineral Processing” [6].

Эти вызовы могут быть преодолены с помощью искусственного интеллекта. Например, точная настройка параметров процесса — это область, где применение ИИ и машинного обучения показало значительный успех в снижении затрат и повышении эффективности. По мере усложнения заводов и увеличения числа датчиков на производственной линии искусственный интеллект помогает аналитикам данных и специалистам по данным превращать данные в ценный актив для компании [6]. ИИ является мощным инструментом для прогнозирования энергопотребления предприятия, что позволяет оптимизировать потребление и избегать потерь.

Danish Ali и Samuel Frimpong представляют перспективные применения машинного обучения на всех этапах производственного процесса в статье [7]. Рассматриваются различные области: работа горного оборудования, геологоразведка, бурение и переработка полезных ископаемых.

Постановка задачи

Постановка задачи. Основные сложности при прогнозировании энергопотребления в промышленных процессах связаны с нелинейной динамикой самих систем и стохастическим характером внешних факторов. Нейронные сети, особенно рекуррентные нейронные сети (RNN), такие как LSTM и GRU, представляют собой надежные инструменты, способные учитывать эти сложности благодаря своей способности моделировать нелинейные уравнения и работать с последовательными данными. Модели

прогнозирования делятся на одношаговые, которые направлены на предсказание одного значения в будущем, и многошаговые, предназначенные для прогнозирования интервала будущих значений. В данной статье основное внимание уделяется многошаговому подходу [8] для оценки эффективности моделей при различных временных интервалах: 30 минут, 180 минут и 360 минут.

Цель заключается в прогнозировании расхода пара на последующие N временных шагов. Учитывая наблюдаемые значения за предыдущие k временных шагов $X_t, X_{t-1}, \dots, X_{t-k}$, мы определяем входную матрицу $X_{t-k:t}$ размера (n, k) , где n — количество признаков, а k — длина временного окна. Задача состоит в том, чтобы спрогнозировать значения расхода пара на следующие N временных шагов, $\widehat{E}_{t+1}, \widehat{E}_{t+2}, \dots, \widehat{E}_{t+N}$ с помощью предиктивной модели F .

$$\widehat{E}_{t+1}, \widehat{E}_{t+2}, \dots, \widehat{E}_{t+N} = F(X_{t-k:t}) \quad (1)$$

Цель — минимизировать расхождение между фактическими значениями расхода пара и теми, которые предсказаны моделью F .

$$\sum_{t=0}^T \|\widehat{E}_t - E_t\| \rightarrow \min, \quad (2)$$

где $\widehat{E}_t$ обозначает прогнозируемый расход пара, а E_t — истинное значение.

Разведочный анализ данных (Exploratory Data Analysis, EDA). Набор данных включает более 40 столбцов, и нам необходимо спрогнозировать значение одного из них, которое соответствует расходу пара. Как видно из рис. 1, сигнал расхода пара не проявляет четкой сезонности или циклического поведения в рамках рассмотренного интервала времени.

Проведя корреляционный анализ, мы обнаружили, что коэффициент корреляции Пирсона между расходом пара и остальными переменными не превышает 0.5. Важно отметить, что отсутствие линейной корреляции не гарантирует отсутствия причинно-следственной связи другого вида. Между переменными могут существовать нелинейные зависимости или сложная взаимосвязь, ко-




Рис. 1. График сигнала расхода пара во времени (отрезок)

торуую невозможно выявить стандартными мерами корреляции. Однако для снижения размерности входных данных и уменьшения вычислительной сложности было принято решение оставить лишь те признаки, абсолютная величина коэффициента корреляции которых с целевой переменной превышала 0,25. Полученные результаты свидетельствуют о лучшей производительности предложенного метода по сравнению с результатами, достигнутыми с полным набором признаков или путем применения анализа главных компонент (PCA).

Построение модели. LSTM (Long Short-Term Memory) относится к категории рекуррентных нейронных сетей, разработанных для решения задачи распознавания долгосрочных зависимостей. Это достигается за счёт эффективного хранения и использования информации на протяжении длинных последовательностей данных [9]. Такая архитектура позволяет преодолеть проблему затухающего градиента, с которой сталкиваются классические RNN.

GRU (Gated Recurrent Unit) – это ещё один вариант рекуррентной нейронной сети. В GRU входной и забывающий гейты LSTM объединены в один обновляющий гейт, что делает структуру GRU более простой по сравнению.

CNN-LSTM – это гибридная нейронная сеть, которая показала хорошие результаты в прогнозировании поведения промышленных систем [5]. Свёрточный слой извлекает важные характеристи-

ки из последовательных данных, а LSTM-слой моделирует долгосрочные зависимости внутри последовательности.

Результаты экспериментов и их обсуждение

Тестовая выборка делится на N последовательностей; для каждой последовательности вычисляются метрики, а затем рассчитывается среднее значение этих метрик, чтобы получить итоговую метрику. Для краткосрочного горизонта (30 минут) и среднесрочного горизонта (180 минут) наилучшие результаты показывает модель GRU. Однако при долгосрочном прогнозировании (360 минут) более точные предсказания обеспечивает модель LSTM. Эффективность моделей снижается с увеличением горизонта прогнозирования, что вполне ожидаемо.

Хотя модель демонстрирует низкие значения по метрикам MSE, MAE и MAPE, это не обязательно указывает на высокую прогностическую способность в данном случае. Напротив, относительно низкие значения ошибок в основном обусловлены тем, что данные по расходу пара, как правило, остаются в узком диапазоне с ограниченной вариативностью в течение нескольких часов. Поэтому даже модель с ограниченной прогностической способностью может показывать низкие значения оценочных метрик. Более тщательное изучение выявило, что модель испытывает затруднения при попытке уловить резкие скачки расхода пара (рис. 2 а–в).

Таблица 1

Результаты экспериментов

Forecast horizon	LSTM			GRU			CNN-LSTM		
	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE
30	1,77	0,10	0,24	1,55	0,08	0,21	1,61	0,08	0,22
180	3,26	0,34	0,44	2,96	0,28	0,40	3,82	0,43	0,51
360	3,71	0,48	0,49	3,84	0,49	0,51	4,22	0,62	0,56




Рис. 2. Прогноз на горизонт 30 минут (а), на 180 минут (б) и на 360 минут (в)

Такие внезапные колебания часто плохо прогнозируются, что говорит о необходимости дальнейшего совершенствования модели для лучшего учета подобных ситуаций.

Возможные направления улучшения

В настоящее время прогноз будущих значений расхода пара основывается исключительно на прошлых наблюдениях (см. формулу 1). Хотя такой подход позволяет учитывать общие тенденции, он ограничен в своей способности прогнозировать резкие изменения или зависящие от контекста колебания. Чтобы решить эту проблему, мы предлагаем стратегию улучшения, заключающуюся во включении дополнительных будущих данных, которые могли бы оказать существенное влияние на колебания расхода пара, приводящее к формулировке следующего типа:

$$\widehat{E_{t+1:t+n}} = F(X_{t-k:t}, Z_{t+1:t+n}) \quad (3)$$

где $Z_{t+1:t+n}$ обозначает известные или запланированные внешние факторы, которые предположительно влияют на будущее поведение системы. Примеры включают заранее спланированные производственные планы, внешние управляющие воздействия и др. Добавление таких вспомогательных данных о будущем позволит модели лучше прогнозировать и реагировать на внезапные изменения расхода пара, тем самым повышая точность прогнозирования.

Заключение

Данная статья определяет методологический подход, применяемый для прогнозирования расхода пара в процессе металлургического производства. Мы оценили три типа нейронных сетей: GRU, LSTM и гибридную архитектуру CNN-LSTM. Исходя из экспериментальных результатов модель GRU показала лучшие результаты для краткосрочных (30 минут) и среднесрочных (180 минут) прогнозов, в то время как модель LSTM обеспечила более точную работу на горизонте долгосрочного прогноза (360 минут). Низкий уровень ошибок частично объясняется тем, что значения расхода пара удерживаются в достаточно узком диапазоне

на протяжении нескольких часов. Однако модели испытывают трудности с прогнозированием резких колебаний. В качестве возможного усовершенствования мы предлагаем рассмотреть включение внешних факторов будущего характера, таких как планируемые события, чтобы помочь модели лучше отслеживать внезапные изменения.

Библиография

1. Amalou, I., Mouhni, N., Abdali, A. Multivariate time series prediction by RNN architectures for energy consumption forecasting. *Energy Rep.* 8, 1084–1091 (2022). <https://doi.org/10.1016/j.egy.2022.07.139>.
2. Agrawal, R. K., Muchahary, F., Tripathi, M. M. Long term load forecasting with hourly predictions based on long-short-term-memory networks. In: 2018 IEEE Texas Power and Energy Conference (TPEC). pp. 1–6 (2018).
3. Khandelwal, I., Adhikari, R., Verma, G. Time Series Forecasting Using Hybrid ARIMA and ANN Models Based on DWT Decomposition. *Procedia Comput. Sci.* 48, 173–179 (2015). <https://doi.org/10.1016/j.procs.2015.04.167>
4. Somu, N., Raman M. R. G., Ramamritham, K. A deep learning framework for building energy consumption forecast. *Renew. Sustain. Energy Rev.* 137, 110591 (2021). <https://doi.org/10.1016/j.rser.2020.110591>.
5. Zha, W., Liu, Y., Wan, Y., Luo, R., Li, D., Yang, S., Xu, Y. Forecasting monthly gas field production based on the CNN-LSTM model. *Energy.* 260, 124889 (2022). <https://doi.org/10.1016/j.energy.2022.124889>.
6. Mishra, A. K. Minerals | AI4R2R (AI for Rock to Revenue): A Review of the Applications of AI in Mineral Processing, <https://www.mdpi.com/2075-163X/11/10/1118>.
7. Ali, D., Frimpong, S. Artificial intelligence, machine learning and process automation: existing knowledge frontier and way forward for mining sector. *Artif. Intell. Rev.* 53, 6025–6042 (2020). <https://doi.org/10.1007/s10462-020-09841-6>.
8. Time series forecasting | TensorFlow Core, https://www.tensorflow.org/tutorials/structured_data/time_series.
9. Shiri, F. M., Perumal, T., Mustapha, N., Mohamed, R. A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU, <http://arxiv.org/abs/2305.17473>, (2023).

PREDICTIVE ANALYTICS OF STEAM CONSUMPTION IN METALLURGICAL PRODUCTION USING NEURAL NETWORKS

Paul Zouaoui^{1,a}, Dmitry O. Sannikov^{2,b}, Vladimir N. Khokhlovskiy^{1,c}

¹Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

²JSC “Kola Mining and Metallurgical Company”, Monchegorsk Russia

^apaul.jean-zouaoui@mail.ru, ^bSannikovDO@kolagmk.ru,

^chohlovskiy_vn@spbstu.ru

Abstract. Providing accurate forecasting of energy consumption is critical in the Metal & Mining sector to avoid losses. However, it is also a big challenge due to the high number of parameters and the non-linear dynamic of the systems. This article aims to provide an assessment of different Neural Networks to forecast steam consumption in the metallurgy manufacturing process. In this study Long Short-Term Memory (LSTM), Gate Recurrent Unit (GRU) and hybrid CNN-LSTM are evaluated. The results are assessed using three metrics: Mean Absolute Percentage Error, Mean Absolute Error, and Mean Squared Error to evaluate each model. Although the error metrics are low, this is mainly attributable to the fact that steam consumption values remain within a relatively narrow range over extended periods, rather than reflecting the model's true predictive capability. The model exhibits limited ability to detect abrupt energy consumption changes. To address this limitation, we propose a potential improvement approach, which is discussed at the end of the paper.

Keywords. Predictive analytics, Energy Consumption, Industrial AI, Neural Networks.

* * *

УДК 330.1

doi:10.18720/SPBPU/2/id25-522

ОБЪЯСНИМЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В СИСТЕМАХ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ

Макарова Арина Александровна¹, Малыхина Галина Федоровна²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹makarova2.aa@edu.spbstu.ru, ²malyhina_gf@spbstu.ru

Аннотация. В статье рассматривается проблема «черного ящика» в системах поддержки принятия решений (СППР) в промышленности,

применяющих методы искусственного интеллекта (ИИ). Непрозрачность влечет за собой недоверие к решениям и затрудняет внедрение таких систем. Представлен обзор популярных Model-Agnostic методов объяснимого ИИ (XAI), направленных на повышение прозрачности и интерпретируемости моделей. Приведены примеры применения XAI в промышленных СППР для прогнозирования качества продукции и оптимизации производственных процессов. Целью статьи является ознакомление с основными подходами XAI и демонстрация их потенциала для повышения эффективности и доверия к ИИ-решениям в промышленной сфере.

Ключевые слова. Искусственный интеллект, модели “черного ящика”, объяснимость, объяснимый искусственный интеллект, Model-Agnostic методы, системы поддержки принятия решений в промышленности.

Введение

В настоящее время в связи со стремительным увеличением объемов анализируемых данных и наглядному подтверждению эффективности методов искусственного интеллекта в различных областях, наблюдается тенденция к внедрению методов искусственного интеллекта в промышленную сферу для повышения конкурентоспособности предприятий и оптимизации процессов их работы. В частности, многие современные СППР в своей основе задействуют, как методы машинного обучения, так и принципы глубокого обучения [17].

Несмотря на то, что применение ИИ повышает производительность, точность прогнозирования и расширяет возможности выявления скрытых закономерностей в данных, оно также привносит с собой определенные недостатки.

Наибольшее количество вопросов с точки зрения доверия в верности получаемых результатов вызывает так называемый принцип “черного ящика”, привносимый многими методами машинного и глубокого обучения в разрабатываемую систему. Т.е. хоть система и может предлагать высокоэффективное и точное решение, у конечных пользователей могут оставаться вопросы, почему именно предложенное решение является оптимальным и что повлияло на предлагаемый результат [4]. Данная непрозрачность затрудняет

профессиональную оценку верности рекомендаций и порождает сложности при возникновении внештатных ситуаций. Соответственно, недоверие существенно затрудняет внедрение разрабатываемых систем на предприятиях.

Еще одним важным моментом является то, что качество работы СППР на базе ИИ напрямую зависит от качества обучающей выборки [3]. Следовательно, неправильно подобранные данные в совокупности с исходной непрозрачностью модели могут привести к поздним обнаружениям ошибочных результатов. Если, например, в изначальных данных будет присутствовать некоторая предвзятость [13], она может остаться незамеченной в процессе разработки и унаследоваться алгоритмами машинного обучения, тем самым повлияв на конечный ответ.

Возникает вполне резонный вопрос, почему бы не использовать более простые и, соответственно, прозрачные модели [19]. Однако применение классических методов, дающих более быстрые и понятные получаемые результаты, часто приводит к потере точности [2].

Тогда исследователи задалась целью “приоткрыть” завесу “черного ящика”, сохранив при этом высокую точность. Вследствие этого появилась активно развивающаяся область объяснимого искусственного интеллекта (XAI), призванная повысить прозрачность и интерпретируемость моделей ИИ. Методы объяснимого ИИ позволяют не только облегчить отладку и повысить степень доверия к разрабатываемым системам, но и помочь в оптимизации.

Обзор методов объяснимого искусственного интеллекта

Описание классификации. Прежде чем применить методы объяснимого искусственного интеллекта (XAI) в систему поддержки принятия решений (СППР), необходимо четко определить конкретные цели и задачи, которые должны быть решены с помощью XAI — оптимизация разрабатываемой системы, поиск и устранение потенциальной уязвимости к входным данным или повышение

ние доверия пользователей посредством объяснений работы. Из поставленной задачи становится ясно, на каком этапе необходимо внедрять объяснимость — до обучения модели или после.

Для упрощения поиска подходящего метода существуют различные классификации методов ХАИ.

По масштабу объяснений методы разделяются на локальные, ориентированные на объяснение результатов для отдельных экземпляров, и глобальные, стремящиеся предоставить общее понимание поведения модели. Дополнительно, методы ХАИ могут дифференцироваться по типу выходных данных (таблицы, текст, изображения и т.д.) и решаемых задач (классификация, сегментация и т.д.) [18].

По ориентированности методов на конкретную модель или на широкий круг моделей они разделяются на Model-Specific и Model-Agnostic, соответственно. В рамках данной статьи будет представлен обзор наиболее распространенных Model-Agnostic методов ХАИ.

Обзор Model-Agnostic методов объяснимого ИИ.

LIME (Local Interpretable Model-agnostic Explanations). Одним из наиболее популярных методов в ХАИ за счет своего интуитивно понятного подхода и простоты работы является LIME. Он предоставляет локальные объяснения и направлен на поиск признаков, оказавших наибольшее влияние на результат конкретного предсказания.

Идея LIME заключается в аппроксимации поведения исходной модели, являющейся “черным ящиком”, в небольшой окрестности исследуемого экземпляра более простой и интерпретируемой моделью. Помимо классического метода существуют и различные его модификации [10].

Для объяснимых СППР в промышленности LIME может применяться, например, в системах прогнозирования отказов и сбоев производственного оборудования для выявления, какие показатели датчиков наиболее критичны для предсказания будущего сбоя [6]. Это позволит сотрудникам понимать, на что обращать повышенное внимание при диагностике.

SHAP (SHapley Additive exPlanations). В отличие от LIME, SHAP является более теоретически подкрепленным и способен представлять как локальное, так и глобальное объяснение.

Метод берет за основу теорию кооперативных игр и позволяет справедливо распределить вклад каждого признака в итоговое предсказание модели. SHAP активно задействуется в современных СППР в промышленности [20, 16, 14], кроме того существуют также различные подходы к методу, применимые к широкому кругу задач и рассмотренные в [12] на примере обработки естественного языка.

Partial Dependence Plots (PDP). Отличается простотой интерпретации и является методом глобального объяснения. Подход позволяет визуализировать, то, как изменение конкретного признака влияет на прогноз модели. Однако, в отличие от SHAP, метод получает результаты из расчета независимости признаков, что в некоторых случаях может привести к выводам, вводящим в заблуждение [21].

С помощью PDP, например, можно выявить пороговые значения для входных данных, выход за пределы которых сигнализирует о высоком риске возникновения неисправности [6]. Также возможно рассчитать оптимальное количество каждого признака для повышения прочности на сжатие сверхпрочного бетона [8].

Individual Conditional Expectation (ICE) Plots. Метод напоминает Partial Dependence Plots, но вместо отображения среднего влияния признака, находит влияние признака для каждого экземпляра в наборе данных. Это позволяет увидеть неоднородность и взаимодействие признаков [7], что упускает PDP, однако становится сложнее в интерпретации.

Permutation Feature Importance (PFI). Идея метода заключается в оценке важности признака путем случайного перемешивания его значений и анализа влияния внесенных изменений на точность предсказания [9]. Относительно прост в реализации и способен работать с коррелированными признаками.

Accumulated Local Effects (ALE). В отличие от Partial Dependence Plots, ALE стремится устранить проблему корреляции признаков и

вместо усреднения прогнозов Accumulated Local Effects вычисляют средние различия в прогнозах [11].

Важно уточнить, что в данной статье рассматривается малая часть из многообразия методов ХАИ и для более полного представления стоит ознакомиться с иными обзорами [11, 5].

Часть перечисленных методов уже активно применяется в СППР в промышленности. Примеры некоторых из них представлены далее.

Применение ХАИ в СППР

Данная система [20] СППР в промышленном производстве использует generalized boosted regression model (GBM) для прогнозирования качества продукции, в частности, шероховатости поверхности стальной полосы, основываясь на данных о производственном процессе. Чтобы обеспечить прозрачность и понимание прогнозов, применяются методы объяснимого ИИ: Partial Dependence Plot (PDP) и Accumulated Local Effects (ALE) для визуализации влияния переменных, Shapley Additive Explanation (SHAP) для объяснения отклонений прогнозов для конкретных наблюдений, и метод параллельных координат для визуального сравнения продуктов и определения направления необходимых изменений переменных для улучшения качества.

Для решения проблемы недостаточной эффективности традиционных методов улучшения качества в условиях современных производств с высокими размерностями данных и нелинейными зависимостями, предложена двухэтапная модель [16]. На первом этапе с помощью адаптированного метода SHAP определяется важность производственных параметров для приоритизации процессов улучшения качества. На втором этапе на основе теории управления качеством выбираются оптимальные действия для улучшения, учитывая нелинейные зависимости в данных. Результаты тестирования модели на реальном производстве полупроводников показали повышение выхода годной продукции.

В статье [14] рассматривается применение SHAP для улучшения поддержки принятия решений в контексте управления цепочками поставок (Supply Chain, SC), характеризующихся высокой степенью неопределенности. Исследование стремится показать влияние ХАИ на качество принимаемых решений в SC.

После тщательного исследования в статье [15] представлена новая методология, задействующая принципы объяснимого ИИ и направленная на повышение интерпретируемости систем поддержки принятия решений на основе ИИ.

Пример применения PFI

В контексте ИИ работа с данными играет ключевую роль в обучении работоспособной модели. Начиная с уменьшения размерности входных признаков и заканчивая устранением неоднозначных данных, способных приводить к предвзятости в работе нейросети или затруднению ее обучения.

Одним из популярных способов снижения размерности является метод главных компонент, преобразующий данные в новую систему координат, где главные компоненты представляют собой направления максимальной дисперсии. Это позволяет сохранить как можно больше информации и одновременно добиться желаемого результата, относительно немного потеряв в точности. Однако за счет таких преобразований появляются значительные затруднения в его интерпретации.

С другой стороны, можно рассмотреть наиболее простой в реализации и интерпретации метод для оценки важности признаков (Permutation Feature Importance) путем перестановок и дальнейшего анализа влияния данных случайных перестановок на величину ошибки модели. Однако конечное решение за тем, какие признаки стоит удалить для уменьшения размерности, остается за человеком, что существенно замедляет процесс работы с данными, но позволяет найти потенциальные проблемы.

В данном разделе будет сравнение данных двух методов с точки зрения снижения размерности с акцентом, преимущественно, на важности PFI.

Исходные данные, представляют собой таблицу, содержащую информацию с датчиков теплоэлектроцентрали (ТЭЦ). Датасет включает 29 признаков, 2 целевых значения (расход мазута паровыми котлами ТЭЦ (target 1) и температуру мазута на линии ТЭЦ (target 2)) и более 14000 строк, представляющих числовые значения. Модель, построенная на основе полного набора признаков, демонстрирует высокую точность предсказаний целевых переменных. Однако, наличие такого большого количества признаков может приводить к ряду проблем, таких как переобучение, увеличение вычислительных затрат, снижение интерпретируемости модели, невыявление потенциальных предвзятостей. Чтобы этого избежать, необходимо выяснить, на что опирается нейросеть.

После обучения модели на всех данных анализ признаков показал, что вклад двух последних столбцов существенно превосходит вклад остальных, что может свидетельствовать, в основном, либо о ненужности других данных, либо о потенциальной предвзятости.

Таким образом, было выявлено, что нейросеть при предсказании расхода мазута паровыми котлами сильно полагается на общую сумму потребления мазута котлами (28) и величину потребления мазута водогрейными котлами (29). Т.к. оценивается расход мазута паровыми котлами, то, вероятно, общая сумма потребления мазута также не будет известна, что приведет к ошибоч-




Рис. 1. Диаграмма важности для 29 признаков



Рис. 2. Диаграмма важности для 28 признаков



Рис. 3. Диаграмма важности признаков, промежуточные результаты

ным суждениям нейросети и ее вероятной неработоспособности на реальных данных. Соответственно, необходимо исключить данный признак. После удаления общей суммы потребления мазута, нейросеть выявила ложную закономерность между потреблением мазута водогрейными (29) и паровыми (target 1) котлами, что неверно.

Аналогичная работа по устранению предвзятостей проделывалась также для признаков, приводящих к предсказанию температуры мазута на линии ТЭЦ. После, для уменьшения размерности,

Таблица 1

Сравнение способов уменьшения размерности

Метод	№ target	MSE_train	MSE_test	MSE_val
Главные компоненты	1	0.005561	0.00653	0.0066676
	2	0.010569	0.011044	0.011058
PFI	1	0.005499	0.005057	0.0052553
	2	0.0068992	0.0071753	0.0079866

стороны, при использовании метода главных компонент для понижения размерности входных параметров интерпретация результата затруднительна. Ниже представлена сравнительная таблица, отражающая полученные среднеквадратичные ошибки:

Из табл. 1 видно, что оба метода (Principal Component Analysis (PCA) [1] и Permutation Feature Importance (PFI)), показали сопоставимую эффективность в минимизации среднеквадратичной ошибки (MSE). Данный результат указывает на то, что оба подхода способны результативно сократить количество признаков, сохраняя при этом репрезентативность данных. Тем не менее, существенное различие заключается в степени интерпретируемости полученных результатов. В то время как PCA преобразует исходные признаки в главные компоненты, сложные в интерпретации, PFI предоставляет непосредственно оценку значимости каждого исходного признака для прогнозирования. Соответственно, в задачах, требующих объяснения и понимания причинно-следственных связей, метод Permutation Feature Importance является более предпочтительным выбором. Однако, если данные для обучения не содержат предвзятостей и важна скорость получения результата без объяснения, метод главных компонент может быть подходящим вариантом.

Заключение

Внедрение методов искусственного интеллекта в промышленные СППР открывает широкие возможности для повышения конкурентоспособности и оптимизации производственных процессов.




Рис. 4. Диаграмма итоговых признаков и их важности

происходил анализ матрицы корреляций и выделялись столбцы, сильно коррелирующие друг с другом.

Как пример, можно выделить (верхнюю (14), нижнюю (15) и среднюю (16)) температуру мазута в резервуаре, что в связке являются избыточными данными.

Из важности признаков видно, что наибольшее влияние на предсказание расхода мазута паровыми котлами влияет температура питательной воды на рабочем складе мазута (PCM) (11), средняя температура мазута в резервуаре (16), а также влажность мазута на линии ТЭЦ (26). Для предсказания температуры мазута на линии ТЭЦ необходимо знать влажность мазута на котлоагрегатах (25), а также давление мазута на линии ТЭЦ (17). С другой

Однако, непрозрачность многих моделей машинного обучения создает проблемы с доверием к результатам и затрудняет их внедрение. Область объяснимого искусственного интеллекта предлагает решения для повышения прозрачности и интерпретируемости моделей, позволяя понять, как именно принимаются решения.

Следует отметить, что внедрение ХАИ в СППР является непрерывным процессом, требующим тщательного выбора подходящих методов и адаптации их к специфике конкретной задачи. В работе были рассмотрены наиболее популярные Model-Agnostic методы объяснимого искусственного интеллекта, такие как LIME, SHAP, PDP, ICE, PFI и ALE, а также их возможное применение и роль в системах поддержки принятия решений на базе ИИ в промышленности.

Дальнейшее развитие методов ХАИ и их активное внедрение в промышленные СППР будет способствовать более эффективному и безопасному использованию ИИ в промышленности.

В конечном итоге, интеграция методов объяснимого искусственного интеллекта в промышленные СППР не только повысит их практическую ценность, но и будет способствовать более ответственному и осознанному использованию ИИ в промышленности, обеспечивая баланс между эффективностью и прозрачностью.

Библиография

1. **Arsenyev D., Malykhina G., Shkodyrev V.** Industrial process control using DPCA and hierarchical Pareto optimization Processes. — 2023. — Т. 11. — № 12. — С. 3329.
2. **Assis A., Dantas J., Andrade E.** The performance-interpretability trade-off: a comparative study of machine learning models // *Journal of Reliable Intelligent Environments*. — 2025. — Т. 11. — № 1. — С. 1.
3. **Budach L. et al.** The effects of data quality on machine learning performance // *arXiv preprint arXiv:2207.14529*. — 2022.
4. **Cabiddu F. et al.** Why do users trust algorithms? A review and conceptualization of initial trust and trust over time // *European management journal*. — 2022. — Т. 40. — № 5. — С. 685–706.

5. **Dwivedi R. et al.** Explainable AI (XAI): Core ideas, techniques, and solutions // *ACM Computing Surveys*. — 2023. — Т. 55. — № 9. — С. 1–33.
6. **Gawde S. et al.** Explainable predictive maintenance of rotating machines using lime, shap, pdp, ice // *IEEE Access*. — 2024. — Т. 12. — С. 29345–29361.
7. **Goldstein A. et al.** Peeking inside the black box: Visualizing statistical learning with plots of individual conditional expectation, // *Journal of Computational and Graphical Statistics*. — 2015. — Т. 24. — № 1. — С. 44–65.
8. **Kashem A. et al.** Hybrid data-driven approaches to predicting the compressive strength of ultra-high-performance concrete using SHAP and PDP analyses // *Case Studies in Construction Materials*. — 2024. — Т. 20. — С. e02991.
9. **Khan A. et al.** Using Permutation-Based Feature Importance for Improved Machine Learning Model Performance at Reduced Costs // *IEEE Access*. — 2025.
10. **Knab P. et al.** Which LIME should I trust? Concepts, Challenges, and Solutions // *arXiv preprint arXiv:2503.24365*. — 2025.
11. **Linardatos P., Papastefanopoulos V., Kotsiantis S.** Explainable ai: A review of machine learning interpretability methods // *Entropy*. — 2020. — Т. 23. — № 1. — С. 18.
12. **Mosca E. et al.** SHAP-based explanation methods: a review for NLP interpretability // *Proceedings of the 29th international conference on computational linguistics*. — 2022. — С. 4593–4603.
13. **Ntoutsis E. et al.** Bias in data-driven artificial intelligence systems—An introductory survey // *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. — 2020. — Т. 10. — № 3. — С. e1356.
14. **Olan F. et al.** Enabling explainable artificial intelligence capabilities in supply chain decision support making // *Production Planning & Control*. — 2025. — Т. 36. — № 6. — С. 808–819.
15. **Panagoulas D. P. et al.** Intelligent decision support for energy management: A methodology for tailored explainability of artificial intelligence analytics // *Electronics*. — 2023. — Т. 12. — № 21. — С. 4430.
16. **Senoner J., Netland T., Feuerriegel S.** Using explainable artificial intelligence to improve process quality: evidence from semiconductor manufacturing // *Management Science*. — 2022. — Т. 68. — № 8. — С. 5704–5723.
17. **Soori M. et al.** AI-based decision support systems in Industry 4.0, A review // *Journal of Economy and Technology*. — 2024.
18. **Speith T.** A review of taxonomies of explainable artificial intelligence (XAI) methods // *Proceedings of the 2022 ACM conference on fairness, accountability, and transparency*. — 2022. — С. 2239–2250.
19. **Tarkhov D., Lazovskaya T., Malykhina G.** Constructing physics-informed neural networks with architecture based on analytical modification of numerical

methods by solving the problem of modelling processes in a chemical reactor. *Sensors*. — 2023. — Т. 23. — № 2. — С. 663.

20. **Tiensuu H. et al.** Evidence-based and explainable smart decision support for quality improvement in stainless steel manufacturing // *Applied Sciences*. — 2021. — Т. 11. — № 22. — С. 10897.

21. **Xin X., Hooker G., Huang F.** Why you should not trust interpretations in machine learning: adversarial attacks on partial dependence plots // *arXiv preprint arXiv:2404.18702*. — 2024.

EXPLICABLE ARTIFICIAL INTELLIGENCE IN DECISION SUPPORT SYSTEMS

Arina A. Makarova¹, Galina F. Malykhina²

Peter the Great St. Petersburg Polytechnic University,
St. Petersburg, Russia

¹makarova2.aa@edu.spbstu.ru, ²malykhina_gf@spbstu.ru

Abstract. The article examines the problem of a “black box” in decision support systems (DSS) in industry using artificial intelligence (AI) methods. Opacity leads to distrust of solutions and makes it difficult to implement such systems. An overview of popular Model-Agnostic explicable AI (XAI) methods aimed at increasing transparency and interpretability of models is presented. Examples of the use of XAI in industrial DSS for predicting product quality and optimizing production processes are given. The purpose of the article is to introduce the main approaches of XAI and demonstrate their potential to increase efficiency and confidence in AI solutions in the industrial sector.

Keywords. Artificial intelligence, black box models, explainability, explicable artificial intelligence, Model-Agnostic methods, decision support systems in industry.

* * *

УДК 004.896

doi:10.18720/SPBPU/2/id25-523

ОРГАНИЗАЦИЯ БОЛЬШИХ ДАННЫХ ДЛЯ ОБУЧЕНИЯ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ УПРАВЛЕНИЯ ТЭЦ

Соловьева Анастасия Альбертовна¹, Мalykhina Галина Федоровна²

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹solovieva_aa@spbstu.ru, ²malykhina_gf@spbstu.ru

Аннотация. В последние годы наблюдается значительный рост объемов данных, которые собираются и обрабатываются в различных отраслях, включая энергетику. Организация и анализ больших данных становятся ключевыми факторами для повышения эффективности и надежности систем управления. В данной работе рассматривается процесс организации больших данных для обучения интеллектуальной системы управления теплоэлектроцентрали (ТЭЦ) с использованием методов машинного обучения.

Ключевые слова. Большие данные, обработка данных, база данных, машинное обучение, IsolationForest, аномалии, фильтрация.

Введение

В последнее время для повышения конкурентоспособности компании прилагают большие усилия для повышения эффективности производства путем анализа данных, которые могут быть собраны в ходе производственного процесса. По мере расширения сферы систем управления объем данных, собираемых в процессе производства, также постоянно увеличивается.

Машинное и глубокое обучение используются в качестве методов получения значимой информации о состояниях процессов из больших объемов данных о сложных производственных процессах, и они часто используются для изучения важных переменных для улучшения качества или информации, определяющей качество. В этом случае высокая производительность модели достигается при достаточно большом объеме собранных данных. Однако иногда

в данных, собранных при отказе оборудования или техническом обслуживании и ремонте, появляются аномальные значения, а они влияют на конечную производительность моделей машинного обучения [3].

Обнаружение аномалий в машинном обучении можно рассматривать как контролируемую, полуконтролируемую или неконтролируемую проблему. Контролируемые и полуконтролируемые настройки требуют меток и полагаются на два последовательных шага: обучение и тестирование. В контролируемой настройке шаг обучения выполняется на обычных и ненормальных данных, тогда как в полуконтролируемой настройке во время обучения используются только обычные экземпляры [5]. Случай без учителя является наиболее привлекательным из-за непредсказуемости аномалий и сложности маркировки наборов данных. Локальный фактор выброса, метод опорных векторов и Isolation Forest являются одними из самых популярных неконтролируемых методов, хотя существует и много других подходов, например, использование автокодировщиков, законов корреляции и т. д.

Структура данных

Для хранения данных котлоагрегатов ТЭЦ была выбрана реляционная структура в PostgreSQL, сочетающая надежность хранения с эффективным доступом к временным рядам. На рис. 1 представлена архитектура базы данных. Основу составляет таблица тегов, содержащая метаданные измеряемых параметров — названия, единицы измерения и привязку к оборудованию. Каждый тег имеет связанную таблицу временного ряда с метками времени, значениями параметров.

Такая архитектура обеспечивает быстрый доступ к историческим данным за счет индексирования по времени и отдельного хранения тегов, что упрощает аналитические запросы. Отдельные таблицы для каждого параметра оптимизируют производительность при работе с большими объемами данных и масштабируемость системы [4]. PostgreSQL поддерживает сложные аналити-




Рис. 1. Архитектура базы данных

ческие функции, включая оконные агрегации и статистические расчеты, что критически важно для последующего обнаружения аномалий.

Структура позволяет напрямую интегрироваться с системами визуализации и аналитическими инструментами, а при необходимости может быть расширена за счет специализированных решений для временных рядов. Это создает баланс между надежностью хранения промышленных данных и гибкостью их обработки для диагностики оборудования.

Метод Isolation Forest

В данной работе для поиска аномалий был использован метод Isolation Forest, так как он обладает высокой эффективностью при работе с большими данными и способностью быстро изолировать аномалии, что делает его особенно полезным в условиях, когда данные содержат шум. В отличие от других методов, он не требует предположений о распределении данных и хорошо справляется с различными типами аномалий, что делает его более универсальным и надежным выбором для анализа.

Isolation Forest — это класс ансамблевых методов, которые объединяют несколько алгоритмов для повышения точности и надежности обнаружения аномалий. Isolation Forest изолирует аномалии, случайным образом выбирая признак и разделяя данные. Благодаря этому аномалии быстро изолируются, поскольку они редки и отличаются. Ядром алгоритма Isolation Forest является

Isolation Tree (iTree), бинарная древовидная структура. Каждое дерево строится путем рекурсивного разбиения данных. В каждом узле случайным образом выбирается признак, и случайное значение разделения выбирается между минимальным и максимальным значениями этого признака.

Точки данных, значения признаков которых меньше или равны значению разделения, попадают в левое поддерево, а остальные — в правое поддерево. Этот процесс продолжается до тех пор, пока каждая точка данных не будет изолирована в своем собственном узле листа или не будет достигнута предопределенная высота дерева. Аномалии, будучи немногочисленными и разными, имеют тенденцию быстро изолироваться, что приводит к более коротким путям в дереве.

Алгоритм вычисления оценки аномальности точки данных основан на наблюдении, что структура iTrees аналогична структуре двоичных деревьев поиска (BST): завершение во внешнем узле iTree соответствует неудачному поиску в BST.

Следовательно, оценка среднего значения $h(x)$ для завершения во внешнем узле совпадает с оценкой неудачных поисков в BST, которая задается формулой:

$$c(m) = \begin{cases} 2H(m-1) - \frac{2(m-1)}{n}, & m \in (2, +\infty) \\ 1, & m = 2 \\ 0, & m \in (-\infty, 2) \end{cases} \quad (1)$$

где n — размер тестового набора, m — размер обучающей выборки, H — гармоническое число, вычисляемое как $H(i) = \ln(i) + \gamma$, где $\gamma = 0,5772156649$ (постоянная Эйлера-Маскерони).

Функция $c(m)$ представляет собой среднее значение $h(x)$ при заданном m , что позволяет нормализовать $h(x)$ и получить оценку аномальности для точки x :

$$s(x, m) = 2 \frac{-E(h(x))}{c(m)}, \quad (2)$$

где $E(h(x))$ — среднее значение $h(x)$ по ансамблю iTrees.

Интерпретация оценки аномальности $s(x, m)$:

- если s близко к 1, то x с высокой вероятностью является аномалией.
- если s меньше 0.5, то x скорее всего нормальная точка.
- если все точки выборки имеют оценку около 0,5, то вся выборка, вероятно, состоит из нормальных данных [6].

После применения метода Isolation Forest в данных было выявлено приблизительно 7% аномальных значений. Эти выбросы могли существенно искажать результаты анализа, поэтому их исключение позволило повысить достоверность дальнейших исследований. Полученный очищенный набор данных был использован для построения регрессионной модели, что обеспечило более точное прогнозирование ключевых показателей оборудования.

Регрессионная модель

В рамках исследования была построена регрессионная модель для прогнозирования производительности оборудования (productivity) на основе расхода мазута (fuel_oil_consumption) для двух режимов: оптимальный и неоптимальный.

Для прогнозирования использовалась линейная регрессия — метод, который пытается установить линейную зависимость между признаками и целевой переменной. Модель подбирает такие коэффициенты при признаках, чтобы минимизировать сумму квадратов разностей между предсказанными и фактическими значениями. Это обеспечивает простую и понятную интерпретацию влияния каждого признака на результат.

В качестве регрессионной модели применялась линейная регрессия с методом наименьших квадратов. Для оценки качества модели использовался комплекс метрик:

- Среднеквадратичная ошибка (Mean Squared Error, MSE);
- Корень из среднеквадратичной ошибки (Root Mean Squared Error, RMSE);
- Средняя абсолютная ошибка (Mean Absolute Error, MAE);
- Коэффициент детерминации (R^2);
- Объяснённая дисперсия (Explained Variance Score, EVS).




Рис. 2. Регрессия на данных с аномалиями




Рис. 3. Регрессия на данных без аномалий

Для визуализации результатов построены графики рассеяния истинных и предсказанных значений на полном (рис. 2) и очищенном (рис. 3) наборе данных, которые позволяют качественно оценить соответствие модели.

Таблица 1

Сравнение модели, обученной на исходном и очищенном наборе данных

Метрики	Набор данных с аномалиями	Набор данных без аномалий
MSE	3,5443	2,1043
RMSE	1,7732	1,4180
MAE	0,8943	0,7753
R ²	0,9476	0,9833
EVS	0,9501	0,9865

Сравнительный анализ (табл. 1) показал, что очистка данных от выявленных аномалий способствует улучшению всех показателей качества модели.

Таким образом, интеграция методов обнаружения выбросов и расширенный набор метрик оценки регрессии обеспечивают более надёжную и точную постановку задачи прогнозирования и управления в производственном контексте [1, 2].

Заключение

В данной работе исследуются подходы к повышению эффективности производственных процессов за счет анализа технологических данных. Основное внимание уделено проблеме выявления аномальных значений в показаниях оборудования, которые могут искажать результаты анализа.

Для решения этой задачи был применен метод Isolation Forest, показавший хорошие результаты при работе с промышленными данными. Этот алгоритм продемонстрировал способность эффективно выявлять отклонения без предварительных предположений о характере распределения данных.

Хранение и обработка информации организованы с использованием реляционной базы данных PostgreSQL. Разработанная структура хранения обеспечивает быстрый доступ к историческим данным и поддерживает аналитические функции, необходимые для мониторинга оборудования.

В рамках исследования построена регрессионная модель зависимости производительности оборудования от расхода мазута. После устранения выявленных аномалий точность модели значительно повысилась: среднеквадратичная ошибка уменьшилась на 40 %, а коэффициент детерминации увеличился до 0,98.

Результаты подтверждают практическую ценность предварительной обработки данных для промышленной аналитики. Перспективным направлением является внедрение систем реального времени для оперативного выявления отклонений. Предложенный подход может быть использован для оптимизации производственных показателей и профилактики нештатных ситуаций. Перспективным направлением дальнейших исследований является разработка автоматизированных систем мониторинга состояния оборудования в реальном времени.

Библиография

1. Многокритериальная оптимизация технологических процессов на основе динамического МГК и нейросетевых моделей. / Г. Ф. Мalykhina, В. П. Шкодырев // Мягкие измерения и вычисления. — 2023. — № 10–2. — С. 60–75.
2. Нейросетевые модели управления промышленной экосистемой / Д. Я. Чавелипарамбил, Г. Ф. Мalykhina // Системный анализ в проектировании и управлении. Сборник научных трудов XXVII Международной научно-практической конференции: в 2-х частях. — Санкт-Петербург. — 2024. — С. 124–139.
3. Обнаружение аномалий больших данных неструктурированных системных журналов / О. И. Шелухин, В. С. Рябинин // Вопросы кибербезопасности. — 2019. — № 2(30). — С. 36–41.
4. Оценка эффективности обработки больших объемов данных в реляционных и колоночных форматах / В. А. Белов, Д. Ю. Ильин, Е. В. Никульчев // Вычислительные технологии. — 2022. — № 3. — С. 46–65.
5. Data Preprocessing Combination to Improve the Performance of Quality Classification in the Manufacturing Process / E. Cho, T.W. Chang, G. Hwang — URL: <https://www.mdpi.com/2079-9292/11/3/477> (дата обращения 23.04.2025). — Текст : электронный.
6. Isolation-Based Anomaly Detection / F. T. Liu, K. M. Ting, K. M. Zhou — URL: <https://dl.acm.org/doi/10.1145/2133360.2133363> (дата обращения 2.05.2025). — Текст : электронный.

ORGANIZING BIG DATA FOR LEARNING THE INTELLIGENT MANAGEMENT SYSTEM OF THE CHP

Anastasia A. Soloveva¹, Galina F. Malykhina²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹solovieva_aa@spbstu.ru, ²malykhina_gf@spbstu.ru

Abstract. In recent years, there has been a significant increase in the volume of data that is collected and processed in various industries, including energy. The organization and analysis of big data are becoming key factors for improving the efficiency and reliability of management systems. This paper examines the process of organizing big data for training an intelligent CHP control system using machine learning methods.

Keywords. Big data, data processing, database, machine learning, Isolation Forest, anomalies, filtering.

* * *

УДК 681.518.5

doi:10.18720/SPBPU/2/id25-524

ГЕОМЕТРИЧЕСКИЙ И КЛАСТЕРНЫЙ ПОДХОД К ОЦЕНКЕ СОСТОЯНИЯ ТЕХНОЛОГИЧЕСКОГО ОБОРУДОВАНИЯ

Беднарский Артем Александрович¹, Селиванова Елена Николаевна²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹super.sparki202@gmail.com, ²selivanova_en@spbstu.ru

Аннотация. В статье рассматривается метод анализа параметров технологического оборудования в пределах одного штатного режима работы. Предлагается использовать кластеризацию и геометрический анализ для разбиения данных внутри доверительной зоны. Сравниваются алгоритмы K-means, GMM и иерархическая кластеризация. Методика позволяет проводить диагностику оборудования и выявлять отклонения от нормальной работы до появления явных признаков неисправности.

Ключевые слова. Предиктивный анализ, кластеризация, иерархическая кластеризация, K-means, GMM, геометрический анализ, доверительная зона.

Введение

Современные подходы к техническому обслуживанию оборудования всё чаще переходят от планово-предупредительных схем к предиктивной диагностике, основанной на анализе данных [1 – 4]. В основе таких систем лежит сбор и анализ большого массива технологических данных, отражающих параметры работы оборудования в реальном времени [5, 6]. Для анализа оборудования можно применять геометрический подход, при котором на основе исторических наблюдений строится область допустимого функционирования оборудования – так называемая доверительная зона. Появление новых точек за её пределами трактуется как потенциальная аномалия или начало деградации оборудования.

Однако такой подход не учитывает важного аспекта: внутри доверительной зоны, соответствующей штатному режиму, данные могут иметь сложную структуру. Практика показывает, что даже при отсутствии аномалий наблюдаемые параметры оборудования могут сдвигаться, группироваться или формировать локальные скопления [7]. Эти эффекты могут отражать переходы между подрежимами, начальные стадии износа или другие слабовыраженные изменения технического состояния, которые ещё не привели к отклонению от нормы, но уже сигнализируют о потенциальных рисках.

Цель настоящего исследования – разработать и апробировать методику анализа технологических данных в пределах одного нормального режима работы оборудования. Предлагается использовать методы кластеризации для выявления внутренней структуры наблюдений, а также геометрические методы построения доверительной зоны для фиксации допустимой области функционирования. Такой подход позволяет не только отслеживать факт выхода за норму, но и диагностировать изменения внутри нормы, расширяя возможности предиктивного анализа [8, 9].

Постановка задачи

В процессе эксплуатации технологического оборудования даже в условиях устойчивого, штатного режима могут наблюдаться отклонения в поведении параметров, не выходящие за пределы допустимого диапазона. Такие изменения могут проявляться в виде дрейфа, миграции или группировки точек внутри доверительной зоны. Игнорирование этих особенностей приводит к потере возможности раннего выявления потенциальных сбоев или скрытых деградационных процессов.

Задачи настоящей работы заключаются в том, чтобы:

- сформировать доверительную зону оборудования с помощью геометрического метода ConvexHull, на основе отфильтрованных исторических данных с помощью метода межквартильного размаха (IQR);
- применить методы кластеризации (K-means, GMM, иерархическую кластеризацию) для анализа структуры данных внутри доверительной зоны;
- выявить наличие внутренних кластеров, отражающих различные подрежимы или изменение характера работы;
- проанализировать пространственную структуру и эволюцию кластеров, выявить их динамику, плотность и взаимное расположение;
- оценить применимость такого подхода для раннего выявления изменений состояния оборудования до выхода за пределы нормы.

Таким образом, задача сводится не к выявлению аномалий как таковых, а к структурному анализу нормального режима, что открывает возможности для более глубокой диагностики и прогнозирования изменений технического состояния оборудования.

Методика оценки состояния оборудования

Оценка состояния технологического оборудования в рамках одного штатного режима осуществляется поэтапно, с использованием методов геометрического и кластерного анализа. Предлагаемая

методика направлена на изучение внутренней структуры данных, отражающих «нормальное» функционирование системы, с целью выявления скрытых тенденций или подрежимов, предшествующих выходу за допустимые границы.

Сбор и предварительная обработка данных. На первом этапе осуществляется накопление исторических измерений технологических параметров, относящихся к известному штатному режиму работы оборудования. Из выборки удаляются пропущенные и некорректные значения, после чего применяется фильтрация выбросов с помощью метода межквартильного размаха (IQR), что позволяет устранить статистически редкие аномалии и сконцентрироваться на основной массе наблюдений.

$$IQR = Q_3 - Q_1;$$

$$B_l = Q_1 - k \cdot IQR;$$

$$B_u = Q_3 + k \cdot IQR.$$

Данные за пределами этих границ считаются выбросами:

$$x < B_l \text{ или } x > B_u.$$

Построение доверительной зоны. На очищенном множестве точек строится доверительная зона, охватывающая весь диапазон нормального режима. Для этого используется алгоритм ConvexHull, формирующий минимальную выпуклую оболочку вокруг точек.

$$Conv(P) = \left\{ \sum_{i=1}^n \alpha_i p_i \mid \alpha_i \geq 0, \sum_{i=1}^n \alpha_i = 1 \right\}.$$

Зона служит геометрической границей допустимого функционирования и используется для визуального и аналитического контроля.

Кластеризация внутри доверительной зоны. На следующем этапе к данным, находящимся внутри доверительной зоны, применяются алгоритмы кластеризации:

– K-means – жёсткая кластеризация с фиксированным числом центров масс.

– Gaussian Mixture Models (GMM) – вероятностная кластеризация, допускающая частичную принадлежность кластерам.

– Иерархическая кластеризация – формирует вложенные подгруппы без необходимости заранее задавать количество кластеров.

Все методы реализуются на одном и том же множестве данных, что позволяет сравнить полученные структуры и их интерпретируемость. Для визуализации используются графики рассеяния с цветовой маркировкой кластеров, а также построение единой общей доверительной зоны.

Анализ результатов кластеризации. Распределение точек между кластерами анализируется с точки зрения: пространственной структуры (отдалённость, плотность, форма и количество кластеров) и степени перекрытия кластеров. Это позволяет выявить скрытые изменения поведения оборудования, которые ещё не привели к выходу за нормативные пределы, но уже сигнализируют о потенциальных рисках.

Результат кластеризации данных

Для демонстрации предложенной методики был использован синтетический набор данных, имитирующий параметры оборудования в пределах одного штатного режима. После предварительной очистки выборки методом межквартильного размаха (IQR) и построения доверительной зоны с помощью алгоритма ConvexHull была проведена кластеризация тремя алгоритмами: K-means, GMM и иерархической кластеризацией.

Каждый метод был применён к одному и тому же множеству наблюдений. Результаты визуализированы в виде графиков рассеяния, где точки окрашены в соответствии с принадлежностью к кластерам, а также построена общая доверительная зона, охватывающая всё множество данных (рис. 1–3). Для алгоритмов кластеризации было автоматически определено оптимальное количество кластеров на основе соответствующих метрик: Silhouette Score – для K-means и BIC – для GMM. Это позволило избежать ручной




Рис. 1. Кластеризация данных методом K-means




Рис. 2. Кластеризация данных методом GMM




Рис. 3. Кластеризация данных иерархическим методом

настройки параметров и получить разбиение, наиболее соответствующее структуре данных.

K-means продемонстрировал стабильное разбиение на три компактных кластера. Метод показал хорошую адаптацию к внутренней структуре данных, несмотря на геометрические ограничения (сферическая форма кластера). Это разбиение оказалось оптимальным в выбранном диапазоне.

GMM на тех же данных определил оптимальное разбиение на два кластера, согласно минимальному значению BIC. Разделение, характерное для GMM, не дало значимого преимущества в анализе текущих данных. Кроме того, чувствительность к параметрам модели усложняет интерпретацию.

Иерархическая кластеризация показала неустойчивое поведение: полученное разбиение на кластеры либо сливалось в один, либо формировало плохо различимые группы, что не соответствовало наблюдаемой структуре. Это объясняется плотным и равномерным распределением точек, при котором иерархический метод не может надёжно определить границы. Данный алгоритм показал себя наименее эффективным в текущем эксперименте.

На рассматриваемом наборе данных наилучшие результаты продемонстрировал K-means, как по формальным метрикам, так и по визуальной интерпретируемости кластеров. Его способность к простому и устойчивому разбиению делает его предпочтительным инструментом для анализа внутренней структуры параметров оборудования в условиях нормального режима работы. На основании визуального и количественного анализа можно выделить следующие наблюдения:

- некоторые кластеры формируют ядро распределения — основную массу точек, характеризующих стабильную работу оборудования.

- другие кластеры имеют смещённую пространственную структуру — точки отстоят от центра распределения и могут указывать на локальные изменения условий (например, изменение нагрузки, внешней температуры, износ).

Таким образом, даже в пределах одного режима работы оборудования не демонстрирует равномерное поведение. Структура распределения параметров внутри доверительной зоны может содержать важную диагностическую информацию, указывающую на скрытые процессы, не выявляемые при стандартной бинарной оценке «норма/аномалия».

Заключение

В работе предложен подход к оценке состояния технологического оборудования на основе кластерного анализа параметров, в пределах одного штатного режима работы оборудования. Методика включает предварительную фильтрацию данных методом межквартильного размаха, построение общей доверительной зоны с использованием геометрического алгоритма ConvexHull и применение алгоритмов кластеризации (K-means, GMM, иерархическая кластеризация). Дополнительно для каждого алгоритма было автоматически определено оптимальное количество кластеров с помощью метрик качества разбиения. Результаты эксперимента показали, что на плотных и однородных выборках наилучшее качество и интерпретируемость кластеров обеспечивает метод K-means.

Проведённый анализ подтвердил, что даже внутри одного режима работы параметры оборудования могут группироваться в подструктуры, отражающие микропроцессы, тенденции или начальные стадии изменений состояния. Выявление таких внутренних кластеров открывает возможности для раннего диагностирования сбоев, адаптивного построения индекса здоровья оборудования и более точного и детального прогноза состояния технологического оборудования. Предложенный подход может быть интегрирован в системы предиктивной диагностики и мониторинга промышленного оборудования. Перспективным направлением дальнейших исследований является расширение методики на временные ряды, а также обновление кластерной структуры в реальном времени. Это позволит повысить точность анализа и выявлять потенциальные отклонения задолго до возникновения критических сбоев.

Библиография

1. Буров А. Ю., Бахтизин А. Р., Ковалев Г. А. Методы интеллектуального анализа данных. — М.: ИНФРА-М, 2018. — 384 с.
2. Колесников А. В., Кульба В. В., Трошин С. А. Методы и модели системного анализа. — М.: Высшая школа, 2007. — 318 с.
3. Болотов С. В. Разработка метода анализа отклонений ключевых показателей эффективности производства под управлением киберфизической системы / С. В. Болотов, Е. С. Гебель, В. В. Потехин, А. С. Жуненков // Наука и технологии в трансформации социально-экономического ландшафта : сборник научных трудов по материалам 9-ой Международной научно-практической конференции, Санкт-Петербург, 29–30 ноября 2023 года. — Санкт-Петербург: Центр научно-информационных технологий «Астерион», 2024. — С. 132–139.
4. Петров В. Е. Цифровой двойник производственной линии сортировки изделий / В. Е. Петров, Е. С. Гебель // Неделя науки ИКНХ : Материалы докладов научно-практической конференции, Санкт-Петербург, 15–17 апреля 2024 года. — Санкт-Петербург: Санкт-Петербургский политехнический университет Петра Великого, 2024. — С. 288–290.
5. Гаврилова Т. А., Хорев Б. С. Знания: извлечение, формализация, передача. — СПб.: Питер, 2016. — 288 с.
6. Лузарев К. А. Система показателей технического состояния запорно-регулирующей арматуры / К. А. Лузарев, Е. С. Гебель // Автоматизация, мехатроника, информационные технологии : Материалы VIII Международной научно-технической интернет-конференции молодых ученых, Омск, 16 мая 2018 года / Ответственный редактор В. Г. Хомченко. — Омск: Омский государственный технический университет, 2018. — С. 168–172.
7. Соловьев В. Д., Каширин А. А. Применение методов кластерного анализа в задачах технической диагностики // Вестник машиностроения. — 2012. — №7. — С. 38–41.
8. Яковлев А. И., Протасов В. Ю. Анализ и моделирование сложных систем: учебное пособие. — М.: МГТУ им. Н.Э. Баумана, 2019. — 232 с.
9. Кашницкий Ю. Открытый курс машинного обучения. Тема 7. Обучение без учителя: PCA и кластеризация [Электронный ресурс] // Хабр. — 2017. — URL: <https://habr.com/ru/companies/ods/articles/325654/> (дата обращения: 01.06.2025).

GEOMETRIC AND CLUSTER APPROACH TO ASSESSING THE CONDITION OF TECHNOLOGICAL EQUIPMENT

Artem A. Bednarsky¹, Elena N. Selivanova²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹super.sparki202@gmail.com, ²selivanova_en@spbstu.ru

Abstract. The article discusses a method for analyzing the parameters of process equipment within one standard operating mode. It is proposed to use clustering and geometric analysis to partition data within a confidence zone. K-means, GMM, and hierarchical clustering algorithms are compared. The technique allows for equipment diagnostics and detection of deviations from normal operation before obvious signs of malfunction appear.

Keywords. Predictive analysis, clustering, hierarchical clustering, K-means, GMM, geometric analysis, confidence zone.

* * *

УДК 004.896:681.5

doi:10.18720/SPBPU/2/id25-525

ДВУХВЕТВЕВАЯ СВЕРТОЧНАЯ НЕЙРОННАЯ СЕТЬ С МЕХАНИЗМОМ ВЫЯВЛЕНИЯ ЗАКОНОМЕРНОСТЕЙ ВО ВХОДНЫХ ДАННЫХ ДЛЯ ПРОГНОЗИРОВАНИЯ ОСТАТОЧНОГО РЕСУРСА ПОДШИПНИКОВ

Го Чэньси¹, Бахрами Амирхоссин²,
Потехин Вячеслав Витальевич³

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹chenxiguo.academic@gmail.com, ²ah.bahrami@hotmail.com,

³Slava.Potekhin@spbstu.ru

Аннотация. С ростом интеллектуальности промышленного оборудования мониторинг состояния и прогнозирование неисправностей становятся ключевыми для обеспечения безопасности производства и повышения эффективности оборудования. В данной работе предлагаем модель прогнозирования остаточного ресурса подшипников — двухвет-

вевую CNN-сеть трансформатора (Dual-Branch CNN Transformer Net, DBCT-Net). Модель сочетает в себе двухветвевую сверточную нейронную сеть (CNN) и механизм самовнимания трансформатора, что позволяет более точно извлекать признаки как во временной, так и в частотной областях. Модель выполняет многомерное слияние признаков и анализирует эффективность использования долгосрочных зависимостей в данных временных рядов. Эксперименты, проведенные на реальных данных, показали, что предложенная модель значительно превосходит базовую модель по точности прогнозирования, что свидетельствует о ее эффективности в мониторинге и прогнозировании остаточного срока службы оборудования.

Ключевые слова. Прогнозирование срока службы, глубокое обучение, многомерное слияние признаков, анализ временных рядов, прогнозирование неисправностей, мониторинг состояния.

Введение

С развитием интеллектуальных технологий промышленное оборудование требует надёжного мониторинга состояния и точного прогнозирования отказов для повышения безопасности и эффективности. Подшипники качения, как ключевые элементы, играют важную роль в стабильности работы систем, а их повреждения часто развиваются незаметно, но быстро прогрессируют, что может привести к серьёзным поломкам [1,2].

Деграция подшипников зависит от множества факторов: рабочие условия, нагрузки, нестабильные внешние воздействия. Традиционные методы, основанные на статистике и физике, обладают ограниченной точностью. Например, Конг и др. [3] применяли метод RMS, а Соуали и др. [4] — преобразование Хилберта—Хуанга совместно с SVM для прогнозирования остаточного срока службы (RUL).

Современные методы, основанные на данных, такие как машинное и глубокое обучение, обеспечили заметный прогресс в области диагностики и прогнозирования. Цуй и др. [5] представили трансформер с кросс-вниманием, Ян и др. [6] предложили двухслойную TCN с механизмом CSA для прогноза срока службы.

Однако существующие модели часто игнорируют многомерность данных, особенно недостаточно эффективно объединяют признаки из временной и частотной областей. CNN и LSTM дают хорошие результаты, но не справляются с глобальными зависимостями. Модели Transformer показывают высокий потенциал, но требуют дальнейшей адаптации для обработки сложных признаков деградации.

Для решения этих проблем в данной работе предложена модель DBCT-Net, которая объединяет двусторонние CNN и механизм само-внимания Transformer для глубокой обработки временных и частотных данных подшипников.

Основные инновации:

1. Двусторонние CNN позволяют извлекать признаки из временной и частотной областей параллельно, что снижает потери информации и обеспечивает полное описание деградации.
2. Механизм самовнимания Transformer улучшает понимание долгосрочных зависимостей в временных рядах, адаптивно перераспределяя внимание между признаками.
3. Сравнительные эксперименты на реальных данных показали превосходство предлагаемой модели по точности прогноза RUL по сравнению с существующими подходами.

Структурные модели и модули

Обзор предлагаемой модели. Структура предложенной модели Dual-Branch CNN-Transformer Net (DBCT-Net) показана на рис. 1. DBCT-Net состоит из трех основных частей: модуль извлечения признаков, слой слияния признаков и слой энкодера Transformer. Сначала модуль извлечения признаков выполняет извлечение признаков для временных данных как в временной, так и в частотной области. Затем с помощью слоя слияния признаков данные из двух областей признаков объединяются и реконструируются. Наконец, с помощью слоя энкодера Transformer обработанные данные слияния признаков используются для получения результатов прогнозирования.




Рис. 1. Структура DBCT-Net

Кроме того, для устранения проблемы исчезающих градиентов была введена структура остаточной связи [7], которая обеспечивает возможность передачи информации через несколько уровней, что улучшает эффективность и стабильность обучения сети.

Модуль извлечения признаков состоит из моделей извлечения признаков во временной области и в частотной области. Цель модели извлечения признаков во временной области заключается в извлечении временных признаков из входных временных сигналов. Цель модели извлечения признаков в частотной области — извлечение частотных признаков из сигнала. Кроме того, для повышения способности модуля извлечения признаков к выражению характеристик в модуле был добавлен слой Dropout. Предположим, что в предыдущем слое сети есть N нейронов.

В модели извлечения признаков во временной области предполагается, что входные данные временных рядов представлены

как $x_t \in \mathbb{R}^{N \times L}$. Для захвата грубых временных признаков используется больший размер свертки. Расчетный процесс выглядит следующим образом:

$$y_t = \delta(\text{Conv}(x_t)) = W_5 * x_t + b_t,$$

где $\text{Conv}(\cdot)$ — процесс одномерной свертки; δ — функция активации ReLU; W_5 — свертка размером 5×5 ; b_t — смещение вычислений.

В модели извлечения признаков в частотной области аналогично используется одномерная свертка для извлечения частотных признаков. Однако в отличие от модели извлечения признаков во временной области этот модуль использует меньшие свертки для захвата более детализированных временных признаков, так как маленькие свертки повышают чувствительность модели к частотным признакам. Расчетный процесс данного модуля выглядит следующим образом:

$$y_f = \delta(\text{Conv}(x_f)) = W_3 * x_f + b_f,$$

где W_3 — свертка размером 3×3 ; b_f — смещение вычислений.

Слой слияния признаков объединяет временные y_t и частотные y_f признаки. Интегрируя два различных уровня и представления признаков, этот слой усиливает выразительные возможности модели и позволяет сети одновременно учитывать информацию как из временной, так и из частотной области. Сначала данный модуль получает два типа признаков, затем с помощью одномерной свертки данные соединяются. Расчетный процесс выглядит следующим образом:

$$y_F = W_F * \text{Contact}(y_t, y_f) + b_F,$$

где $\text{Contact}(\cdot)$ обозначает процесс объединения y_t и y_f вдоль канала; b_F — смещение вычислений.

Слой энкодера Transformer. Сначала, с помощью модели самовнимания, вычисляются влияния каждого элемента на текущий элемент [7], используя три матрицы запрос (Q), ключ (K) и значение (V). Предположим, что входные данные признаков

представлены как X . Конкретный процесс выглядит следующим образом:

$$O_S = \text{softmax} \left(\frac{Q \cdot K^T}{\sqrt{d_k}} \right) \cdot V = \text{softmax} \left(\frac{XW_Q \cdot XW_K^T}{\sqrt{d_k}} \right) \cdot XW_V,$$

где Z — матрица внимания; d_k — размерность K , а — операция нормализации. Затем, используя V , выполняется взвешенное вычисление Z для получения оценки внимания для каждого элемента.

Кроме того, для улучшения способности модели захватывать различные типы зависимостей, используется механизм многоголового самовнимания, который отображает запрос (Q), ключ (K) и значение (V) в несколько подпространств. Предположим, что в модели имеется h голов, процесс вычислений выглядит следующим образом:

$$O_M = \text{Contact}(O_1, O_2, \dots, O_h)W^O,$$

где Q_i , K_i и V_i обозначают запрос, ключ и значение каждой головы; $W^O \in \mathbb{R}^{h \cdot d_k \times D}$ — матрица линейного преобразования; O_M — выход многоголового внимания.

Кроме того, выход механизма самовнимания далее отображается нелинейно с помощью слоя Feed-forward. Модуль состоит из двух полностью связанных слоев и вычисляется следующим образом:

$$O_F = W_2 \cdot \text{ReLU}(W_1 \cdot O_M + b_1) + b_2,$$

где O_F — вывод слоя Feed-forward; W_1 и W_2 — матрицы весов; b_1 и b_2 — смещения.

Наконец, с помощью слоя Pooling выполняется сжатие признаков последовательности, а затем с помощью слоя полной связи (Full connected) сжатые данные отображаются в целевом измерении. Конкретный процесс вычислений выглядит следующим образом:

$$\hat{y} = W_{out} \cdot \frac{1}{L} \sum_{i=1}^L O_M(i) + b_{out},$$

где W_{out} — матрица выходного отображения; L — длина последовательности; b_{out} — смещение.

Результаты моделирования

Для проверки эффективности предложенной модели использован набор данных PHM 2012 для оценки производительности прогнозирования срока службы оборудования. В статье в качестве обучающих данных использованы Bearing1-1 и Bearing1-2, а в качестве тестовых данных — Bearing1-3. Компилятор модели в статье — Pycharm 2023, версия Python 3.11. Аппаратная конфигурация эксперимента: процессор Intel Xeon Platinum 8352V и графический процессор NVIDIA GeForce RTX 4090. Модель обучалась с использованием оптимизатора Adam, скорости обучения 0.00003, 100 эпох, функции потерь MSE, значением Dropout 0.1 и размером пакета 32.

Кроме того, для дальнейшей проверки превосходства предложенной модели, в данной статье проведено сравнение с рядом базовых моделей, включая: CNN-LSTM, GAT-LSTM [8], GAT-TCN [9] и предложенную модель DBCT-Net. Оценка проводится с использованием показателей RMSE и R^2 . Чем ниже значение RMSE, тем меньше погрешность прогноза модели, а чем ближе значение R^2 к 1, тем лучше модель подходит к данным.

Сравнительные данные RMSE и R^2 для различных моделей представлены на рис. 2. Из рисунка видно, что модель DBCT-Net имеет наименьшее значение RMSE и наибольшее значение R^2 .




Рис. 2. Сравнение результатов по RMSE и R^2 для различных моделей




Рис. 3. Результаты прогнозирования DBCT-Net

Таким образом, модель DBCT-Net показывает лучшие результаты по сравнению с другими моделями, что подтверждает её высокую точность предсказания и устойчивость.

Кроме того, для наглядного наблюдения результатов предсказания DBCT-Net, на рис. 3 показаны результаты прогнозирования остаточного срока службы с использованием DBCT-Net. Из рисунка видно, что данный метод обладает хорошей устойчивостью, что подтверждает эффективность и перспективность предложенной модели.

Заключение

Для точного захвата пространственно-временных признаков вибрационных сигналов подшипников предложена модель прогнозирования остаточного срока службы оборудования DBCT-Net. Эта модель сочетает двустороннюю сверточную нейронную сеть (CNN) и механизм самовнимания Transformer, с целью более глубокого извлечения сложных паттернов в временных данных через двустороннюю обработку признаков временной и частотной

областей. Результаты эксперимента показывают, что предложенная модель обеспечивает более точное прогнозирование остаточного срока службы и работы оборудования. Будущие исследования сосредоточены на дальнейшей оптимизации эффективности обучения модели и исследовании переноса обучения на данные из других областей.

Библиография

1. **Wu C.** и др. A Deep Parallel Spatiotemporal Network based on Feature Cross-fusion for Remaining Useful Life Prediction of Aero Engine // IEEE Transactions on Instrumentation and Measurement. – 2025.
2. **Kong X., Yang J.** Remaining Useful Life Prediction of Rolling Bearings Based on RMS-MAVE and Dynamic Exponential Regression Model // IEEE Access. – 2019. – Т. 7. – С. 169705–169714.
3. **Soualhi A., Medjaher K., Zerhouni N.** Bearing Health Monitoring Based on Hilbert–Huang Transform, Support Vector Machine, and Regression // IEEE Transactions on Instrumentation and Measurement. – 2014. – Т. 64, № 1. – С. 52–62.
4. **Cui J.** и др. A Novel Dual-Branch Transformer with Gated Cross-Attention for Remaining Useful Life Prediction of Bearings // IEEE Sensors Journal. – 2024.
5. **Yang X.** и др. Remaining Useful Life Prediction Under Multiple Operating Conditions Based on a Novel Dual-Layer Temporal Convolutional Network // IEEE Sensors Journal. – 2024.
6. **He K.** и др. Deep Residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2016.
7. **Vaswani A.** и др. Attention is All You Need // Advances in Neural Information Processing Systems. – 2017. – Т. 30.
8. **Yang C., Liu J., Zhou K. A.** Residual Life Prediction Method for Bearings Based on Path Graph Attention Network // Journal of Mechanical Engineering. – 2023. – Т. 59, № 12. – С. 195–201.
9. **Wang P., Liu C., Xu J.** и др. An Early Warning Method for Wind Turbine Gearbox Faults Based on Graph Attention and Time Convolution Network // Journal of Electronic Measurement and Instrumentation. – 2023. – Т. 37, № 8. – С. 204.

DUAL-BRANCH CONVOLUTIONAL NEURAL NETWORK WITH SELF-ATTENTION MECHANISM FOR BEARING RESIDUAL LIFE PREDICTION

Guo Chenxi¹, Amirhossein Bahrami², Vyacheslav V. Potekhin³

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹chenxiguo.academic@gmail.com, ²ah.bahrami@hotmail.com,

³Slava.Potekhin@spbstu.ru

Abstract. With the increasing intelligence of industrial equipment, condition monitoring and fault prediction become the key to ensure production safety and improve equipment efficiency. In this paper, we propose a bearing residual life prediction model, Dual-Branch CNN Transformer Net (DBCT-Net.) The model combines a dual-branch convolutional neural network (CNN) and a transformer self-attention mechanism, which enables more accurate feature extraction in both the time and frequency domains. The model performs multivariate feature fusion and analyzes the effective use of long-term dependencies in time series data. The experiments conducted on real data show that, the proposed model significantly outperforms the baseline model in terms of prediction accuracy, which demonstrates its efficiency in monitoring and predicting the remaining useful life of the equipment.

Keywords. Remaining useful life prediction, deep learning, multivariate feature fusion, time series analysis, fault prediction, equipment condition monitoring.

* * *

ИНТЕРАКТИВНЫЙ МЕТОД ДИАГНОСТИКИ НЕИСПРАВНОСТЕЙ НА ОСНОВЕ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ

Ли Цзымин^{1,а}, Ковальчук Елена Александровна^{2,б},
Мишра Аншуман^{1,в}, Потехин Вячеслав Витальевич^{1,г}

¹Санкт-Петербургский политехнический университет Петра Великого,

²ООО «СТЦ», Санкт-Петербург, Россия

^аli66.ts@edu.spbstu.ru, ^бekovalchuk@stc-spb.ru,

^вmishra.a@edu.spbstu.ru, ^гSlava.Potekhin@spbstu.ru

Аннотация. В ответ на комплексные задачи диагностики неисправностей в эпоху Индустрии 4.0 в данной статье предлагается интеллектуальная интерактивная система на основе крупных языковых моделей/Large Language Model (LLM). Система использует механизм RAG (Retrieval-Augmented Generation) для интеграции знаний из промышленной сферы и получения текстовой информации из различных источников, включая базы данных и системы распознавания изображений. Это позволяет достаточно точно диагностировать неисправности. Благодаря предоставлению структурированных диагностических результатов данное решение призвано значительно повысить эффективность управления оборудованием и возможности прогнозирования технического обслуживания. В настоящее время успешно создана архитектура LLM на основе Google Gemini 1.5 Flash и ведется оптимизация системы RAG.

Ключевые слова. Искусственный интеллект, большие языковые модели, диагностика неисправностей, предиктивное обслуживание, RAG-системы, интерактивные методы.

В эпоху быстрого развития Индустрии 4.0 предприятия сталкиваются с беспрецедентными возможностями и вызовами. Из-за своего непосредственного влияния на стабильность производственных процессов, проблемы диагностики и обслуживания являются одними из наиболее приоритетных для предприятий любого масштаба. Ввиду стремительного развития технологий,

традиционные методы диагностики и обслуживания зачастую становятся недостаточными для удовлетворения потребностей современного производства [1].

Такие методы диагностики и обслуживания, промышленного оборудования обычно базируются на заранее заданных расписаниях технического обслуживания и регулярных проверках, и зачастую оказываются неэффективными в предсказании неожиданных сбоев или выявлении начальных стадий деградации. Также, эти методы не учитывают изменения условий эксплуатации [2].

Ранее существующие методы диагностики промышленных неисправностей играли важную роль, но в условиях взрывного роста объемов разнородных данных, таких как данные датчиков, записи о техническом обслуживании, журналы операций и т. п., и потребности в более интеллектуальной и активной диагностике их традиционный режим работы показывает свои ограничения [3]. Некоторые методы прогнозирования неисправностей с использованием ИИ уже существуют, но они в значительной степени опираются на данные [4, 5], собранные датчиками, такими как температура и давление, и являются более сложными для пользователей в практическом применении. Руководство по устранению неисправностей, предоставленное производителем, носит слишком общий характер и не позволяет провести детальный анализ с использованием конкретных данных. LLM может эффективно снизить порог входа для пользователей, обрабатывая текстовую информацию на естественном языке, а также изображения, базы данных и другие данные.

Разработка интеллектуальной системы, способной точно диагностировать и прогнозировать неисправности промышленного оборудования, построенной на основе больших языковых моделей (LLM) Google Gemini 1.5 Flash, послужит для интерпретации описаний неисправностей оборудования на естественном языке. Рабочий процесс системы показан на рис. 1. Важным элементом, способствующим эффективности системы, является ее специализированная база промышленных знаний, заключенная в настраиваемый набор данных. Данная база хранит структурированную




Рис. 1. Рабочий процесс системы

информацию о различных неисправностях оборудования и способах их диагностирования.

Для повышения точности диагностики и обеспечения ее актуальности, внедряем структуру Retrieval-Augmented Generation (RAG). Этот передовой подход позволяет LLM динамически извлекать и синтезировать информацию из построенной базы знаний. Предоставляя LLM контекстуально релевантные данные, RAG гарантирует, что прогнозы не только генерируются интеллектуально, но и прочно основаны на устоявшихся практиках и исторических данных о неисправностях оборудования.

В процессе реализации создана базовая архитектура на основе LLM и сформирована специализированная база знаний о возможных неисправностях. Первоначальные испытания подтверждают способность системы предоставлять релевантные и последовательные диагностические рекомендации. Также разработан веб-интерфейс, который облегчает ввод информации и отображение результатов в процессе тестирования, как показано на рис. 2. В дальнейшем систему можно будет модифицировать в соответствии с требованиями API для подключения к другим программным системам.

В ходе тестирования также создана база знаний (cases.csv — удобный для редактирования онлайн-документ) на основе раздела по диагностике неисправностей в руководстве по CLICK ПЛК [6], которая строго следует шестиколонной структуре: «Название

Помощник по диагностике промышленных неисправностей

Интерактивный метод на основе больших языковых моделей

Системная инструкция для ИИ:

You are a senior industrial equipment maintenance expert and fault diagnosis engineer. Please accurately diagnose potential fault causes based on the equipment and fault symptoms provided by the user, any attached files (like images or data logs), AND ****leveraging the 'Related Knowledge Base Information' provided below****. Then provide detailed, actionable

Название оборудования:

Гидравлический пресс

Подробно опишите симптомы неисправности:

Пресс не развивает полного давления, медленно движется рабочий цилиндр, слышен посторонний шум в районе насоса.

Загрузить файл(ы) с информацией о неисправности:

Выбор файла: 未选择任何文件

Макс. размер одного файла: 50МБ. Поддерживаемые форматы: PNG, JPG, WEBP, PDF, TXT, MD, CSV, WAV, MP3, OGG, FLAC, MP4, WEBM, MOV.

Диагностировать неисправность Изменить базу знаний

Результат диагностики

Здесь появится ваш диагноз.

Рис. 2. Веб-интерфейс ввода/вывода данных

устройства», «Тип неисправности», «Симптомы неисправности», «Возможные причины», «Этапы диагностики» и «Решение», в соответствии с информацией из руководства в базу знаний добавлены 20 строк с информацией о неисправностях, как показано на рис. 3.

В ходе тестирования проведена непосредственная проверка базы знаний, функциональности и эффективности интерактивной диагностической системы на основе модели LLM и архитектуры RAG через веб-интерфейс, как показано на рис. 4. Для тести-

Equipment Name	Fault Type	Fault Symptom	Possible Causes	Diagnostic Steps	Solution
ПЛК CLICK	Проблема с электроснабжением	Индикатор PWR (питание) ВЫКЛ (не горит)	Отсутствует питание на ПЛК	1. Проверить напряжение на клеммах	Заменить источник питания
ПЛК CLICK	Проблема с электроснабжением	Индикатор PWR (питание) МИГАЕТ	Входная мощность ПЛК низкая	1. Проверить напряжение на клеммах	Заменить блок питания
ПЛК CLICK	Ошибка ПЛК	Индикатор ERR (ошибка) ГОРИТ	Ошибка модуля ввода-вывода	1. Подключить программное обеспечение	Устранить причину ошибки
ПЛК CLICK	Предупреждение ПЛК	Индикатор ERR (ошибка) МИГАЕТ	Потеряны данные SRAM	1. Подключить программное обеспечение	Предупреждение
ПЛК CLICK	Проблема с режимом RUN	Индикатор RUN ВЫКЛ (перешел в STOP)	ПЛК находится в режиме STOP	1. Если переключить в режим RUN	Если симптом сохраняется, обратиться к производителю
ПЛК CLICK	Проблема с режимом RUN	Индикатор RUN МИГАЕТ	Для анализа ПЛК инициализирует анализ	1. Продолжить до 11 секунд для завершения	Если симптом сохраняется, обратиться к производителю
ПЛК CLICK	Проблема с электроснабжением	Входное напряжение ПЛК меньше 24В	Блок питания не может обеспечить питание	1. Отсоединить разъем питания от ПЛК	Заменить блок питания
ПЛК CLICK	Проблема с электроснабжением	Входное напряжение ПЛК больше 24В	Выходное напряжение блока питания	1. Если блок питания регулируемый, уменьшить выходное напряжение	
Модуль ввода ПЛК CLICK	Неисправность входа	Входной сигнал присутствует	но светодиодный индикатор не горит	Проблема с внешним питанием модуля	1. Проверить наличие питания
Модуль ввода ПЛК CLICK	Неисправность входа	Светодиодный индикатор на модуле не горит	но ПЛК не реагирует на сигнал	ПЛК не в режиме RUN; Ошибка клемм	1. Убедиться, что ПЛК в режиме RUN

Рис. 3. Пример сформированной базы знаний

Системная инструкция для ИИ:

You are a senior industrial equipment maintenance expert and fault diagnosis engineer. Please accurately diagnose potential fault causes based on the equipment and fault symptoms provided by the user, any attached files (like images or data logs), AND ****leveraging the 'Related Knowledge Base Information' provided below****. Then provide detailed, actionable diagnostic steps and solutions.

Please strictly adhere to the following rules:

- **Reference Knowledge Base:**** Prioritize using the "Related Knowledge Base Information" for diagnosis. If the knowledge base does not contain a direct match, infer based on your general professional knowledge and any provided files.
- **Analyze Files:**** If one or more files are attached (e.g., images of the fault, sensor readings, error logs), incorporate their information into your diagnosis.
- **Professionalism:**** Use professional terminology from the industrial domain.
- **Detail:**** List all possible fault causes, diagnostic steps, and repair measures as comprehensively as possible.
- **Structure:**** Your response should be clearly divided into four sections: "Diagnosis Result," "Possible Causes," "Diagnostic Steps," and "Solution."
- **Ask for More Information:**** If the information (text or file) is insufficient, proactively ask for more details.
- **Language:**** Respond in Russian.

Рис. 4. Команда „Promt на ввод

рования выбраны типичные случаи неисправностей, такие как неработающий индикатор питания (PWR) CLICK ПЛК и работающий индикатор выходного модуля без выхода. Соответствующие описания симптомов из руководства точно введены в систему. В рамках исследования было проведено нечеткое тестирование, включающее описание неисправностей с использованием естественного языка (более разговорного, выполненное носителем). Это позволило имитировать ввод данных пользователем в реальных условиях эксплуатации. Результаты тестирования зафиксированы в журнале сервера, пример которого приведен в табл. 1.

Результат вывода показан на рис. 5. В ходе тестирования были последовательно проверены все 20 строк данных в базе знаний. Точность прямого тестирования составила 100 %, а точность нечёткого соответствия – 90 %. Результаты показали, что информация, содержащаяся в диагностическом отчёте, генерированном LLM, в значительной степени совпадает с данными, представленными в базе знаний. Это подтверждает способность системы RAG извлекать и использовать информацию из файла cases.csv. Это свидетельствует о том, что LLM не выдвигает независимые гипотезы, а эффективно применяет имеющиеся

Таблица 1

Пример проверки валидности базы знаний

Тестовый объект	Информация в базе знаний	Фаза тестирования	Введенная информация о неисправности	Результат точный/ неточный
ПЛК CLICK	Индикатор ERR (ошибка) МИГАЕТ	Прямое тестирование	Индикатор ERR (ошибка) МИГАЕТ	точный
		Нечеткое соответствие	Светодиод ошибки мигает; лампочки ошибки периодически загораются красным и потухают; лампочка ошибки моргает красным цветом	точный

структурированные знания в качестве фундамента для анализа и диагностики.

Результаты тестирования подтвердили эффективность предложенной интерактивной диагностической системы на основе LLM и RAG при использовании структурированной внешней базы знаний (БЗ). Экспериментально доказан потенциал архи-

тектуры RAG для повышения точности LLM в промышленных приложениях и ключевая роль полноты БЗ в производительности системы. При диагностике неисправностей, отсутствующих в БЗ, например, «аномальное срабатывание всех выходных реле без программной команды», LLM, опираясь на общие инженерные знания, предлагает лишь общие гипотезы (помехи, аппаратные сбои), уступая в специфике диагностики на основе БЗ. Предварительное тестирование загрузки файлов, например, изображение индикаторов ПЛК, и влияния системных промптов показало, что, хотя LLM пытается учесть файловую информацию, глубокая интеграция мультимодальной информации требует дальнейшей оптимизации.

Последующие шаги планируется направить на оптимизацию стратегии поиска RAG,

расширение охвата БЗ и углубление интеграции мультимодальной информации.

Данное исследование проведено при поддержке Китайского совета по стипендиям (CSC) (202409010292).

Библиография

1. Анализ экспериментальных исследований активной комбинированной опоры ротора / М. Э. Бондаренко, Р. Н. Поляков, М. А. Токмакова, А. Д. Серебренников // Фундаментальные и прикладные проблемы техники и технологии. — 2023. — № 1(357). — С. 133—139.

2. Родичев А. Ю. Применение методов машинного обучения в диагностике промышленного оборудования / А. Ю. Родичев, И. В. Родичева, К. В. Васильев // XI Всероссийская научно-практическая конференция имени академика А.Г. Шипунова : Материалы XI Всероссийской научно-практической конференции, Орел, 22 марта 2024 года. — Орёл: Орловский государственный университет им. И. С. Тургенева, 2024. — С. 10—14.

3. Multimodal Large Language Model-Based Fault Detection and Diagnosis in Context of Industry 4.0 / K. M. Alsaif, A. A. Albeshri, M. A. Khemakhem, F. E. Eassa // Electronics. — 2024. — Vol. 13, — No. 24, — P. 4912.

4. Потехин В. В. Анализ методов диагностирования и прогнозирования технического состояния газотурбинной установки / В.В. Потехин, Я.В. Лудищев, С.В. Болотов // Вопросы системного технологического перехода : Сборник научных трудов по материалам конференции «Технологическая перспектива: новые рынки и точки экономического роста» 2021—2022. В 2-х томах, Санкт-Петербург, 10—11 ноября 2022 года. — Санкт-Петербург: Центр научно-информационных технологий «Астерион», 2023. — С. 100—107.

5. Потехин В. В. Использование методов машинного обучения для предиктивного анализа при эксплуатации производственных систем / В. В. Потехин, Д. Д. Лядский, С. В. Болотов // Вопросы системного технологического перехода : Сборник научных трудов по материалам конференции «Технологическая перспектива: новые рынки и точки экономического роста» 2021—2022. В 2-х томах, Санкт-Петербург, 10—11 ноября 2022 года. — Санкт-Петербург: Центр научно-информационных технологий «Астерион», 2023. — С. 90—100.

6. CLICK PLC User Manual [Electronic resource] / AutomationDirect. — URL: <https://cdn.automationdirect.com/static/manuals/c0userm/c0userm.html> (date of access: 04.06.2025).




Рис. 5. Результат диагностики

INTERACTIVE METHOD FOR DIAGNOSING INDUSTRIAL FAULTS BASED ON LARGE LANGUAGE MODELS

Ziming Li^{1,a}, Elena A. Kovalchuk^{2,b}, Anshuman Mishra^{1,c}, Vyacheslav V. Potekhin^{1,d}

¹Peter the Great St. Petersburg Polytechnic University,

²LLC “STC”, St. Petersburg, Russia

^ali66.ts@edu.spbstu.ru, ^bekovalchuk@stc-spb.ru,

^cmishra.a@edu.spbstu.ru, ^dSlava.Potekhin@spbstu.ru

Abstract. In response to the complex challenges of fault diagnostics in the Industry 4.0 era, this article proposes an intelligent interactive system based on large language models (LLM). The system uses the RAG (Retrieval-Augmented Generation) mechanism to integrate industrial knowledge bases and obtain textual information from various sources, such as databases and image recognition systems, for accurate fault diagnosis. By providing structured diagnostic results, this solution is designed to significantly improve equipment management efficiency and predictive maintenance capabilities. Currently, an LLM architecture based on Google Gemini 1.5 Flash has been successfully created, and the RAG system is being optimised.

Keywords. Artificial intelligence, large language models, fault diagnostics, predictive maintenance, RAG systems, interactive methods.

* * *

УДК 681.5.015

doi:10.18720/SPBPU/2/id25-527

ОПТИМИЗАЦИЯ ПАРАМЕТРОВ БУРЕНИЯ НА ОСНОВЕ АЛГОРИТМОВ ГРАДИЕНТНОГО БУСТИНГА И РОЯ ЧАСТИЦ

Шейх Ал Ард МХД Сами¹, Кожубаев Юрий Нургалиевич²,
Потехин Вячеслав Витальевич³

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹shejhalard.m@edu.spbstu.ru, ²kozhubaev_yun@spbstu.ru

³Slava.Potekhin@spbstu.ru

Аннотация. Современные буровые операции в нефтегазовом секторе требуют одновременной оптимизации ключевых показателей эффектив-

ности, таких как скорость проходки (ROP), износ инструмента и энергоэффективность. В работе представлен комплексный подход, основанный на данных, который использует машинное обучение и роевой интеллект для прогнозирования и оптимизации ROP. Градиентный бустинг-регрессор (GBR) разработан с использованием реальных параметров бурения и свойств пласта, что позволило достичь высокой точности прогнозирования ($R^2 = 0,92$ при обучении, $0,90$ при тестировании). Используется оптимизация роя частиц (PSO) для определения оптимальных параметров веса инструмента (WOB) и поверхностного числа оборотов (SURF_RPM), что приводит к увеличению ROP на 18 % по сравнению со средними показателями по месторождению. Интегрированная система GBR-PSO предлагает масштабируемое решение для оптимизации бурения в режиме реального времени, снижения затрат и повышения стабильности ствола скважины, что повышает устойчивость процесса добычи ресурсов.

Ключевые слова. Параметры бурения; износ инструмента; градиентный бустинг; метод роя частиц.

Введение

Четвертая промышленная революция (Индустрия 4.0) положила начало эпохе преобразований в нефтегазовой отрасли, характеризующейся внедрением в буровые операции передовых технологий, таких как машинное обучение (ML), искусственный интеллект (AI) и Интернет вещей (IoT). Современные буровые установки превращаются в «умные» благодаря внедрению встроенных датчиков и аналитических платформ реального времени, позволяющих динамически корректировать параметры бурения для минимизации человеческого фактора, повышения эффективности и снижения операционных затрат.

В отличие от традиционного бурения, которое в значительной степени опирается на эмпирические модели и ручную настройку параметров, интеллектуальное бурение использует процесс принятия решений на основе данных для адаптации к условиям недр в режиме реального времени. Это позволяет сократить непроизводительное время (NPT) и снизить риски, такие как застревание трубы или потеря циркуляции. Устойчивое развитие — одна из основ этого технологического сдвига, поскольку отрасль стал-

кивается с растущим давлением, требующим минимизации воздействия на окружающую среду при удовлетворении глобальных потребностей в энергии. Оптимизация процессов бурения не только повышает экономическую эффективность, но и снижает потери ресурсов и негативное воздействие на окружающую среду. Например, повышение скорости бурения на 18% за счет оптимизации параметров с помощью ML может значительно сократить время бурения, тем самым уменьшив выбросы CO₂ при работе буровой установки.

Оптимизация бурения — сложная, многокритериальная задача. На скорость бурения влияет нелинейное взаимодействие между механическими параметрами (WOB, RPM), характеристиками пласта (пористость, объем сланца) и гидравлическими условиями. Традиционные модели ROP, такие как эмпирические уравнения Бургойна и Янга, часто не отражают эти сложности, особенно в гетерогенных пластах. Недавние исследования продемонстрировали превосходство подходов, основанных на данных: искусственные нейронные сети (ИНС) были использованы для прогнозирования ROP в режиме реального времени, а генетические алгоритмы (ГА) оптимизируют параметры бурения при многочисленных ограничениях. Однако ИНС страдают от высоких вычислительных затрат и проблем интерпретации «черного ящика», а ГА могут медленно сходиться при решении задач высокой размерности.

Данная работа устраняет эти пробелы, предлагая новую схему, которая сочетает в себе градиентный бустинг-регулятор (GBR) для прогнозирования ROP и оптимизацию роя частиц (PSO) для оптимизации параметров. GBR отлично справляется с моделированием нелинейных зависимостей и обработкой зашумленных полевых данных, а PSO эффективно исследует пространство параметров для определения оптимальных настроек WOB и RPM, что приводит к значительному улучшению ROP.

Традиционные модели ROP. Эмпирические модели, такие как уравнения Бургойна и Янга, широко использовались для прогнозирования ROP на основе параметров бурения и свойств пласта. Однако эти модели часто не отражают нелинейности и неоднород-

ности, присутствующие в реальных данных, что ограничивает точность прогнозирования и адаптивность.

Машинное обучение в бурении. Последние достижения в области ML позволили разработать более надежные прогнозные модели для буровых работ. Искусственные нейронные сети (ANN) и машины опорных векторов (SVM) применялись для прогнозирования ROP, но эти модели требуют больших вычислительных затрат и сложны для интерпретации. Регрессоры с градиентным бустингом (GBR) обеспечивают высокую точность и лучшую интерпретируемость, отражая сложные нелинейные взаимосвязи и будучи менее склонными к перестройке при правильной настройке.

Оптимизация параметров бурения традиционно опиралась на эвристические подходы, а в последнее время — на эволюционные алгоритмы, такие как генетические алгоритмы (GA) и оптимизация роя частиц (PSO). PSO, вдохновленный коллективным поведением стай в природе, доказал свою эффективность в навигации по высокоразмерным пространствам параметров и эффективном сближении с оптимальными решениями.

Сбор и обработка данных

Набор первичных данных включает в себя измерения в реальном времени, проводимые в процессе эксплуатации ствола скважины, включая параметры бурения: вес на инструмент (WOB), число оборотов на поверхности (SURF_RPM), скорость проходки (ROP_AVG); и свойства пласта: пористость (PHIF), объем сланца (VSH), водонасыщенность (SW).

Первым этапом проведены очистка данных и выявление аномалий. Аномальные измерения были определены с помощью статистических порогов и визуального осмотра. Пробелы в данных заполнялись с помощью интерполяции и правил, характерных для данной области. Все характеристики были стандартизированы с помощью нормализации z-score для обеспечения сопоставимости и улучшения сходимости моделей.

При выборе признаков и снижении размерности проведен анализ главных компонент (PCA) и корреляционный анализ, что послужило снижению избыточности данных и определению наиболее влиятельных признаков для прогнозирования ROP.

Методология

Предложенная методология объединяет градиентную регрессию (GBR) для прогнозного моделирования и оптимизацию роя частиц (PSO) для многоцелевой оптимизации параметров. Система разработана для решения проблемы нелинейной зависимости между параметрами бурения (WOB, RPM) и показателями производительности (ROP, MSE, износ инструмента). Предварительная обработка данных и создание признаков для снижения зашумленности сигналов и выбросов включает ряд последовательных операций:

Удаление выбросов с применением метода интерквартильного размаха (IQR):

$$\begin{aligned} IQR &= Q_3 - Q_1, \text{ Lower Bound} = Q_1 - 1,5 \times IQR, \\ \text{Upper Bound} &= Q_3 + 1,5 \times IQR. \end{aligned} \quad (1)$$

Точки данных, выходящие за эти границы, отбрасываются.

Импутация пропущенных значений — линейная интерполяция для промежутков < 5 секунд:

$$x_t = x_{t-1} + \frac{(t - t_{-1})}{(t_{+1} - t_{-1})} (x_{+1} - x_{-1}). \quad (2)$$

Нормализация — минимально-максимальное масштабирование для стандартизации признаков:

$$\hat{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}. \quad (3)$$

Многомерное обнаружение аномалий с учетом расстояние Махаланобиса для коррелированных параметров:

$$D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} x - \mu}. \quad (4)$$

Модель GBR прогнозирует ROP путем итеративного объединения слабых обучающих устройств (деревьев решений) для минимизации остатков. Модель обучается для оптимизации следующей функции потерь.

Первоначальное предсказание:

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, \gamma). \quad (5)$$

Аддитивное расширение: на каждой итерации m добавляется новое дерево h_m :

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x), \quad (6)$$

где v — скорость обучения, а h_m аппроксимирует отрицательный градиент потерь L (средняя квадратичная ошибка).

Регуляризация: для предотвращения перебора, цель включает в себя штрафные условия:

$$\mathcal{E} = \sum_{i=1}^n L(y_i, F_m(x_i)) + \lambda \sum_{j=1}^T \omega_j^2, \quad (7)$$

где T — количество листьев, а ω_j — вес листьев.

Важность характеристик вычисляется через общее снижение потерь, приписываемое каждой особенности.

Алгоритм PSO определяет оптимальные параметры бурения, уравнивая конкурирующие цели:

$$\text{Maximize } \mathbf{F}(x) = \begin{bmatrix} \text{ROP}(x) \\ -\text{MSE}(x) \\ -\text{WearRate}(x) \end{bmatrix}, \quad (8)$$

с учетом ограничений:

$$\begin{cases} \text{WOB}_{\min} \leq \text{WOB} \leq \text{WOB}_{\max}, \\ \text{RPM}_{\min} \leq \text{RPM} \leq \text{RPM}_{\max}, \\ \text{MSE} \leq \text{MSE}_{\text{threshold}}. \end{cases} \quad (9)$$

Рабочий процесс PSO: 1) инициализация частиц — каждая ча-

стица x_i представляет собой решение-кандидат (WOB, RPM); обновление скорости — для частицы i на итерации $k + 1$:

$$\mathbf{v}_i^{k+1} = w\mathbf{v}_i^k + c_1r_1(\mathbf{p}_{\text{best}_i} - \mathbf{x}_i^k) + c_2r_2(\mathbf{g}_{\text{best}} - \mathbf{x}_i^k), \quad (10)$$

где w — инерция, c_1 и c_2 — коэффициенты ускорения, $r_1, r_2 \sim U(0, 1)$.

Далее получаем обновление позиции:

$$\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1}. \quad (11)$$

Решения ранжируются с использованием доминирования по Парето для выявления компромиссов.

Интеграция с NSGA-II для поиска границ Парето. Для уточнения результатов PSO применяется NSGA-II: быстрая сортировка без преобладания — решения классифицируются по фронтам Парето; расстояние краудинга — поддерживает разнообразие, отдавая предпочтение решениям в менее плотных областях пространства задач; отбор и размножение — турнирный отбор и симулированное бинарное скрещивание генерируют потомство.

Реализация в режиме реального времени. Система работает в замкнутом цикле: сбор данных — датчики собирают данные о WOB,




Рис. 1. Сравнение прогнозов и факта ROP




Рис. 2. Влияние признаков (SHAP-анализ)

оборотах и свойствах пласта с частотой 1 Гц; прогнозирование ГБР — ROP оценивается с использованием текущих параметров; оптимизация PSO — каждые 30 секунд регулирует WOB и RPM, чтобы максимизировать ROP при соблюдении ограничений; проверка — сравниваются прогнозируемый и фактический ROP, см. рис. 1, и модель переобучается на основании данного сравнения.

Количественная оценка вклада параметров подтверждает, что WOB (34 %) и RPM (28 %) являются доминирующими факторами, см. рис. 2.

Заключение

В результате реализации предложенного подхода на данных 12 скважин Пермского бассейна достигнуты следующие результаты: увеличение скорости проходки на 32 %; снижение механической удельной энергии (MSE) на 25 %; уменьшение износа инструмента за счет динамической корректировки WOB и RPM.

Библиография

1. Villarrubia G., De Paz J. F., Chamoso P., De la Prieta F. Artificial neural networks used in optimization problems // *Neurocomputing*. 2018.
2. López A., Thakral M. S. G., Saini R. P., Raj M. R. C. Multi-objective optimization using artificial neural networks in hybrid systems // *Journal of Intelligent & Robotic Systems*. 2020. №98(3). С. 689–703.
3. Хейли Э. Градиентный бустинг: теория и практика // *Интеллектуальные системы*. — 2019. — № 5. — С. 42–50.
4. Кендел Р., Уилсон Э. Интеллектуальные методы оптимизации. — М.: Лаборатория знаний, 2016. — 304 с.
5. Пермяков А. А. Методы анализа данных в геологоразведке. — Екатеринбург: УГГУ, 2021. — 215 с.
6. Kostenko D., Kudryashov N., Maistryshin M., Onufriev V., Potekhin V., Vasiliev A. Digital Twin Applications: Diagnostics, Optimisation and Prediction // *Автоматика. Информатика*. 2020. № 1. С. 106–113.
7. Potekhin V. V., Bahrami A. H., Katalinič B. Developing Manufacturing Execution System with Predictive Analysis // *IOP Conference Series: Materials Science and Engineering*. 15. Сер. “15th International Conference on Industrial Manufacturing and Metallurgy” 2020. С. 012117.

OPTIMISATION OF DRILLING PARAMETERS BASED ON GRADIENT BOOSTING AND PARTICLE SWARM ALGORITHMS

Sami Shekh Al Ard MHD¹, Yury N. Kozhubaev², Vyacheslav V. Potekhin³

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹shejhalard.m@edu.spbstu.ru, ²kozhubaev_yun@spbstu.ru,

³Slava.Potekhin@spbstu.ru

Abstract. Modern drilling operations in the oil and gas sector require simultaneous optimisation of key performance indicators such as rate of penetration (ROP), tool wear, and energy efficiency. This paper presents an integrated data-driven approach that leverages machine learning and swarm intelligence to predict and optimise ROP. A gradient boosted regressor (GBR) is developed using real drilling parameters and formation properties which allows achieving high prediction accuracy ($R^2 = 0,92$ in training, $0,90$ in testing). Particle swarm optimisation (PSO) is used to determine the optimal parameters of weight of tool (WOB) and surface revolution number (SURF_RPM), resulting in an 18% increase in ROP compared to the field average. The integrated GBR-PSO system offers a scalable solution for

real-time drilling optimisation, cost reduction, and improved wellbore stability, which improves the sustainability of the resource production process.

Keywords. Drilling parameters; tool wear; gradient boosting; particle swarm optimisation.

* * *

УДК 519.254+004.9+004.42

doi:10.18720/SPBPU/2/id25-528

ОЦЕНКА ПОГРЕШНОСТИ РЕЗУЛЬТАТОВ КОСВЕННЫХ ИЗМЕРЕНИЙ, ПОЛУЧАЕМЫХ С ИСПОЛЬЗОВАНИЕМ СРЕДСТВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Семенов Константин Константинович

Санкт-Петербургский политехнический университет Петра Великого,

Санкт-Петербург, Россия

semenov_kk@spbstu.ru

Аннотация. В работе рассмотрена задача оценки погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта. Современное развитие технологий нейросетового моделирования привело к их широкому проникновению в том числе в метрологические задачи, не исключая косвенные измерения. Данная статья содержит обзор представленных в литературе применения искусственных нейронных сетей для получения результатов косвенных измерений и обсуждает вопрос оценки их погрешности с учетом особенностей задачи, связанных с применением нейронных сетей. Предложенные в работе соотношения носят унифицированный характер, не зависят ни от типа, ни от структуры задействованных нейронных сетей и позволяют построить полноценное метрологическое обеспечение даже в случае, когда по текущим результатам происходит дообучение нейросетей.

Ключевые слова. Косвенные измерения, искусственные нейронные сети, метрологическое обеспечение, трансформированная погрешность

Введение

Широкое распространение искусственных нейронных сетей как универсального средства аппроксимации сложных зависи-

мостей во многих областях не могли не коснуться и задач метрологии, включая классическую задачу косвенных измерений. Существование данной задачи, заключающейся в определении целевого значения физической величины путем его расчета по уравнению взаимосвязи с другими физическими величинами, чьи значения были измерены, подразумевает использование информации о соответствующей функциональной связи, которая может быть выражена различным образом: в классической постановке — в виде отдельного алгебраического уравнения или системы таких уравнений (возможно, нелинейных и выраженных регрессионными моделями); во многих современных задачах — уже с помощью искусственных нейронных сетей. К применению последних побуждает трудность выбора и построения регрессионных моделей взаимосвязей значений физических величин, измеряемых напрямую и косвенно — особенно при значительном их количестве. Использование искусственных нейронных сетей позволяет в гораздо меньшей степени заботиться об определении конкретного вида изучаемых зависимостей, что является несомненным преимуществом и упрощением при решении соответствующих метрологических задач.

Настоящая работа посвящена задаче оценки погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта, и впервые для метрологической литературы предлагает ее решение.

Обзор применения искусственных нейронных сетей в задачах косвенных измерений

В научной литературе к настоящему времени представлен ряд работ, связанных с использованием искусственных нейронных сетей в задачах косвенных измерений. Ниже представлен их краткий обзор, иллюстрирующий распространение технологии искусственных нейронных сетей на данную область измерительных задач, включая примеры конкретных практических приложений.

Статья [1] описывает оригинальный метод косвенного измерения расхода воды в насосной сети с использованием средств искусственного интеллекта. В работе предложена система обратной связи, основанная на контроллере с нечеткой логикой и ANN, которая строит нелинейную модель для косвенной оценки значения расхода на основе результатов прямых измерений давления, частоты вращения двигателя и угла открытия регулирующего клапана. Авторы отмечают, что такой подход позволил им отказаться от использования дорогостоящих расходомеров со сложной системой их установки, выполняющих прямые измерения. В обзоре [2] рассмотрено текущее состояние применения косвенных измерений в виртуальных датчиках для систем возобновляемой энергетики. Авторы проанализировали основные существующие подходы к построению виртуальных средств измерений, которые на основе доступных результатов косвенных измерений позволяют оценивать ключевые параметры энергетических установок, к которым отнесены, в частности, солнечные панели и ветровые турбины. Кроме того, в работе [2] обсуждены преимущества и недостатки использования методов машинного обучения для повышения точности и надежности результатов измерений, выполняемых на промышленном объекте, без установки дополнительных физических датчиков. В работе [3] представлена разработанная нелинейная динамическая модель двигателя с переключаемым магнитным сопротивлением, которая используется в качестве уравнений косвенных измерений, связывающей результаты прямых измерений тех величин, что могут быть измерены непосредственно, с характеристиками двигателя. В работе для минимизации количества прямых измерений выполнена по сути дела редукция модели с помощью метода опорных векторов в сочетании с методом наименьших квадратов. В статье [4] предложен новый метод оценки магнитокалорического эффекта в соответствующих материалах на основе косвенных измерений с использованием искусственных нейронных сетей. Авторы разработали модель, которая позволяет предсказывать величину указанного эффекта по результатам измерения связанных с ним физических величин. В работе [5]

рассмотрены такие методы косвенных измерений для цифровых сенсорных систем с функциями самообслуживания в контексте так называемой Индустрии 4.0, которые экономически менее затратны, чем организация непосредственных прямых измерений тех же физических величин. Авторы обсуждают возможность минимизации затрат на средства измерений за счет перехода к косвенным измерениям и интеллектуальной обработке сигналов измерительной информации. В статье [6] рассмотрена задача оценки степени загрязнения воздуха в тоннелях на основе косвенных измерений с использованием нейронных сетей. Разработана модель, которая прогнозирует уровни содержания загрязняющих веществ по тем данным о параметрах окружающей среды и технологических процессах, которые поступают по результатам прямых измерений — при этом измерения концентраций загрязнителей напрямую не производятся. В работе [7] выполнена разработка эквивариантных нейронных сетей для обработки результатов косвенных измерений в задачах восстановления и анализа данных. Авторы предложили архитектуры нейросетей, обладающих свойством эквивариантности относительно групповых преобразований для учета симметрии и инвариантности, присущих физическим системам. В статье представлены в том числе результаты численных экспериментов, указывающих на перспективность использования эквивариантных сетей в сравнении с классическими методами обработки косвенных измерений. В статье [8] представлен новый метод выполнения косвенных измерений для параметров нелинейных динамических систем, основанный на специальном методе глубокого обучения — Residual Improved Deep Learning Algorithm (RIDLA). Как отмечают авторы, разработанный подход сочетает глубокое обучение с улучшенной (по сравнению с традиционными методами) математической обработкой остаточных ошибок, что позволяет получить более высокую точность оценки выходных откликов нелинейных динамических систем. Статья [9] посвящена методу обратного моделирования с помощью нейронных сетей, приближающих прямую модель (например, сложного объекта), для оценки параметров на основе результатов косвенных

измерений. Авторы работы предложили использовать обученную нейросеть в качестве быстрого и точного аппроксиматора прямой модели для эффективного решения обратной задачи параметрической идентификации (по сути дела - косвенных измерений) путем подбора параметров, минимизирующих отклонения между результатами прямых измерений и прогнозов модели. В работе [10] предложен подход к решению многопараметрических обратных задач большой размерности, возникающих при обработке результатов косвенных измерений. Авторы предложили комбинированный подход, сочетающий специальные алгоритмы оптимизации и методы машинного обучения и при этом позволяющий восстанавливать большое количество параметров сложных систем на основе ограниченного количества зашумленных результатов прямых измерений. Подход направлен на преодоление сложностей, связанных с высокой размерностью пространства параметров и неоднозначностью решения обратных задач. В статье [11] рассмотрены методы оценки параметров на основе регрессионных моделей при решении задач многомерных косвенных измерений в областях обработки изображений и распознавания образов. В работе [12] представлен метод одновременных косвенных измерений силы вихревых токов для определения подповерхностного распределения значений электрофизических свойств плоских объектов с использованием априорной информации о них, выраженной математической моделью, в качестве которой может быть теоретически использована и искусственная нейронная сеть.

Отдельным направлением использования средств искусственного интеллекта применительно к задачам косвенных измерений является оценка неопределенности результатов косвенных измерений. В настоящее время данный вопрос в научной литературе не исследован. Единственная работа на данную тему — статья [13] — излагает подход к оценке величины неопределенности предсказаний нейронной сети, отображающей уравнение косвенных измерений, унаследованную (трансформированную) от неточности исходных данных. Данная работа, не получившая цитирований, по сути дела излагает классический подход к оценке неопределенно-

сти результата косвенных измерений для случая, когда уравнение косвенных измерений выражено некоторой функцией (например, связывающей выход искусственной нейронной сети с ее входами), конкретный вид которой неизвестен и в этом отношении не предлагает новых результатов по сравнению с общеизвестными — в частности изложенными в Руководстве по выражению неопределенности результатов измерений [14]. Настоящая работа идет дальше статьи [13] и предлагает системное рассмотрение вопроса оценки погрешности косвенных измерений для случая, когда взаимосвязь между результатами прямых и косвенных измерений отображается с помощью искусственной нейронной сети.

Особенности использования искусственных нейронных сетей в задачах косвенных измерений

Использование средств искусственного интеллекта в качестве довольно универсального инструмента аппроксимации взаимозависимостей между результатами прямых совместных измерений, выступающими в качестве входных векторов для нейросети, и результатами косвенных измерений, являющимися ее выходными величинами, имеет ряд особенностей.

1. Как правило, вычисления, выполняемые с применением нейронных сетей, довольно трудоемки, а приближаемые зависимости — довольно сложны, что влечет желательность минимизации количества обращений к нейронной сети или использования при решении соответствующей измерительной задачи существенных вычислительных ресурсов.

2. Поскольку искусственные нейронные сети — это инструмент аппроксимации, отображаемые ими зависимости воспроизводятся сетью принципиально лишь приближенно и не всегда опираются на точные фундаментальные соотношения (при использовании иных классов нейронных сетей недели физически информированные нейронные сети). Величина точности приближения определяется результатами обучения нейронной сети и ее проверки на контрольном датасете.

3. Использование инструмента нейронных сетей допускает возможность их дообучения в ходе использования, что приводит

к переносу погрешностей предшествующих результатов прямых измерений на текущие результаты косвенных измерений (через уточненные веса нейронной сети).

Перечисленные особенности указывают на следующее. При оценке погрешности результатов косвенных измерений, выполняемых с применением искусственных нейронных сетей, необходимо по возможности учитывать остаточную неточность приближения нейросетью взаимосвязи между результатами прямых и косвенных измерений и то обстоятельство, является ли нейронная сеть статичной или происходит дообучение по ходу выполнения измерений. При этом желательно минимизировать количество обращений к нейронной сети для уменьшения времени, затрачиваемого на метрологическое обеспечение получаемых результатов косвенных измерений.

Оценка погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта

Искусственные нейронные сети, используемые в качестве инструмента выражения взаимосвязей между вектором x значений физических величин, измеряемыми напрямую, и вектором y значений физических величин, измеряемых косвенно, с математической точки зрения представляют собой вектор-функцию F многих переменных, зависящую от вектора параметров a , в качестве которых выступают веса нейронной сети:

$$y = F(x, a). \quad (1)$$

Использование нейронных сетей в метрологических задачах в целом имеет следующие варианты:

1) нейронная сеть является постоянной, значения ее весов a определены заранее и во время выполнения измерений считаются неизменными,

2) нейронная сеть является адаптивной и значения весов a изменяются в ходе выполнения измерений, т. е. $a_i = g(x_{i-1}, a_{i-1})$,

где значение индекса указывает на момент выполнения измерения: i – в текущий момент времени, $(i-1)$ – в предшествующий.

Для второго случая формула (1) претерпевает изменения и приобретает следующий вид:

$$\mathbf{y}_i = \mathbf{F}(\mathbf{x}_i, \mathbf{g}(\mathbf{x}_{i-1}, \mathbf{a}_{i-1})). \quad (2)$$

Вектор-функция $\mathbf{g}$ определяется методом дообучения искусственной нейронной сети и ее типом.

Для случая (1) величина пределов погрешности Δ_y определяется известным соотношением, напрямую следующим из локальной линеаризации:

$$\Delta_y \approx \left| \frac{\partial \mathbf{F}(\mathbf{x}, \mathbf{a})}{\partial \mathbf{x}} \right|^T \Delta_{\mathbf{x}} + \Delta_{\mathbf{F}}, \quad (3)$$

где $\Delta_{\mathbf{x}}$ – вектор пределов возможных значений абсолютной погрешности $\Delta_{\mathbf{x}}$ элементов вектора $\mathbf{x}$; $J = \frac{\partial \mathbf{F}(\mathbf{x})}{\partial \mathbf{x}}$ – матрица Якоби для вектор-функции $\mathbf{F}$; $|J|$ – матрица, составленная из абсолютных значений элементов матрицы J ; $\Delta_{\mathbf{F}}$ – предел абсолютной погрешности приближения нейронной сетью (функцией $\mathbf{F}$) действительной зависимости между значениями физических величин, измеряемых напрямую и измеряемых косвенно.

Пусть $\mathbf{c}$ (от англ. control) – вектор входных значений для нейронной сети, соответствующих контрольной выборке, задействованной после выполнения обучения и получения вектора весов $\mathbf{a}$, а $\Delta_{\mathbf{c}}$ – вектор предельных значений абсолютных погрешностей его компонент. Пусть $\mathbf{t}$ (от англ. true) – вектор выходных значений для нейронной сети, с которыми сравниваются ее предсказания $\mathbf{F}(\mathbf{c}, \mathbf{a})$, а $\Delta_{\mathbf{t}}$ – вектор предельных значений абсолютных погрешностей его элементов. Тогда

$$\Delta_{\mathbf{F}} = \max \left\{ \left| \mathbf{F}(\mathbf{c}, \mathbf{a}) - \mathbf{t} \right| - \left| \frac{\partial \mathbf{F}(\mathbf{c}, \mathbf{a})}{\partial \mathbf{x}} \right|^T \Delta_{\mathbf{c}} + \Delta_{\mathbf{t}} \right\}. \quad (4)$$

Данное выражение представляет собой оценку методической погрешности приближения уравнения косвенных измерений нейросетью и отделяется от той составляющей погрешности, что наследуется выходными значениями нейронной сети от погрешности значений на ее входе (трансформируется в ходе вычислений в рамках нейронной сети).

Для случая (2) формула (3) претерпевает изменения, поскольку погрешность текущих выходных значений $\mathbf{y}_i$ теперь наследуется (трансформируется) не только от текущих результатов прямых измерений $\mathbf{x}_i$, но и от весов $\mathbf{a}_i$:

$$\Delta_{y_i} \approx \left| \frac{\partial \mathbf{F}(\mathbf{x}_i, \mathbf{a}_i)}{\partial \mathbf{x}_i} \right|^T \cdot \Delta_{\mathbf{x}_i} + \left| \frac{\partial \mathbf{F}(\mathbf{x}_i, \mathbf{g}(\mathbf{x}_{i-1}, \mathbf{a}_{i-1}))}{\partial \mathbf{x}_{i-1}} \right|^T \cdot \Delta_{\mathbf{x}_{i-1}} + \Delta_{\mathbf{F}}(i-1), \quad (5)$$

где $\Delta_{\mathbf{x}_i}$ – вектор пределов возможных значений абсолютной погрешности $\Delta_{\mathbf{x}_i}$ элементов вектора $\mathbf{x}_i$; $\Delta_{\mathbf{x}_{i-1}}$ – аналогичный вектор для $\Delta_{\mathbf{x}_{i-1}}$; $\Delta_{\mathbf{F}}(i-1)$ – предел абсолютной погрешности приближения нейронной сетью (функцией $\mathbf{F}$) действительной зависимости между значениями физических величин, измеряемых напрямую и измеряемых косвенно, осуществляемого на $(i-1)$ -м шаге измерений до соответствующего дообучения.

Использование выражения (5) сопряжено с трудностями непосредственных по нему расчетов в связи со сложностью вида функции $\mathbf{g}$ и необходимостью метрологического сопровождения процесса дообучения, поскольку

$$\left(\frac{\partial \mathbf{F}(\mathbf{x}_i, \mathbf{g}(\mathbf{x}_{i-1}, \mathbf{a}_{i-1}))}{\partial \mathbf{x}_{i-1}} \right)^T = \left(\frac{\partial \mathbf{F}(\mathbf{x}_i, \mathbf{g}(\mathbf{x}_{i-1}, \mathbf{a}_{i-1}))}{\partial \mathbf{g}} \right)^T \cdot \frac{\partial \mathbf{g}(\mathbf{x}_{i-1}, \mathbf{a}_{i-1})}{\partial \mathbf{x}_{i-1}}.$$

Это обстоятельство не позволяет при дообучении обойтись только лишь стандартными методами и средствами программных библиотек работы с искусственными нейронными сетями.

Есть возможность отнести ту часть погрешности, что наследуется весами нейронной сети при ее дообучении в состав методичес-

кой составляющей Δ_F и тогда выражение (5) может быть заменено близким к (3) соотношением (6):

$$\Delta_{y_i} \approx \left| \frac{\partial F(\mathbf{x}_i, \mathbf{a}_i)}{\partial \mathbf{x}_i} \right|^T \cdot \Delta_{\mathbf{x}_i} + \Delta_F(i), \quad (6)$$

где $\Delta_F(i)$ — уже предел абсолютной погрешности приближения нейронной сетью (функцией F) действительной зависимости между значениями физических величин, измеряемых напрямую и измеряемых косвенно, осуществляемого на i -м шаге измерений после соответствующего дообучения. При этом, если при дообучении на i -м шаге используется та же контрольная выборка, что и на всех предыдущих шагах, то

$$\Delta_F(i) = \max \left\{ \left| F(\mathbf{c}, \mathbf{a}_i) - \mathbf{t} \right| - \left| \frac{\partial F(\mathbf{c}, \mathbf{a}_i)}{\partial \mathbf{x}} \right|^T \cdot \Delta_{\mathbf{c}} + \Delta_{\mathbf{t}} \right\}. \quad (7)$$

Если же контрольный датасет также обновляется, то

$$\Delta_F(i) = \max \left\{ \left| F(\mathbf{c}_i, \mathbf{a}_i) - \mathbf{t}_i \right| - \left| \frac{\partial F(\mathbf{c}_i, \mathbf{a}_i)}{\partial \mathbf{x}} \right|^T \cdot \Delta_{\mathbf{c}_i} + \Delta_{\mathbf{t}_i} \right\}, \quad (8)$$

где $\mathbf{c}_i$ — вектор входных значений для нейронной сети, соответствующих контрольной выборке, задействованной при дообучении последней на i -м шаге; $\Delta_{\mathbf{c}_i}$ — вектор предельных значений абсолютных погрешностей компонент вектора $\mathbf{c}_i$; $\mathbf{t}_i$ — вектор выходных значений для нейронной сети, с которыми при дообучении на i -м шаге сравниваются ее предсказания $F(\mathbf{c}_i, \mathbf{a}_i)$ а $\Delta_{\mathbf{t}_i}$ — вектор предельных значений абсолютных погрешностей его элементов.

Вид соотношений (7) и (8) полностью подобен (4) и позволяет подойти с единых позиций к ситуации, когда используемая в качестве уравнений косвенных измерений искусственная нейронная сеть является неизменной по ходу выполнения измерений, и к ситуации, когда в течение ее эксплуатации происходит дообучение на полученных данных. Данное обстоятельство позволяет считать возможным достигнуть унифицированного метрологического

обеспечения задачи косвенных измерений с применением нейросетей, поскольку приведенные в данном разделе соотношения оказываются одними и теми же для любых типов используемой сети и любых ее структур.

Для оценки погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта по представленным в статье формулам, необходимы значения производных от функции, выраженной нейронной сетью. В работе [13] предлагается для этого использовать конечные разности, что потребует контроля получаемой ошибки в оценках значений производных и значительного количества обращений к нейронной сети: если длина вектора $\mathbf{x}$ равна n , то количество вызовов для каждого расчета оценки погрешности будет равно $(n + 1)$. Представляется, что более удачным является использование автоматического дифференцирования, которым обычно сопровождается процесс обучения нейронной сети при использовании алгоритма обратного распространения ошибки. Соответственно, если интерфейс взаимодействия с нейронной сетью это допускает, что имеет место во многих случаях, уместно для оценки производных использовать часть процедуры обучения для получения текущих значений производных. Временные трудозатраты могут быть эквивалентны примерно $1,5n$ вызовам нейронной сети [15].

Заключение

В данной работе рассмотрена задача оценки погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта. Представлен обзор применения нейросетевых моделей для получения результатов косвенных измерений для разных метрологических задач. Отмечено отсутствие работ, связанных с организацией их такого метрологического сопровождения, которое бы полноценно учитывало бы особенности, связанные с использованием искусственных нейронных сетей.

В работе представлены соотношения (3)–(4), позволяющие оценить величину погрешности результатов косвенных измерений для случая, когда привлекаемая для их получения нейросеть не претерпевает изменений по ходу выполнения измерений. Предложенные формулы (6) и (7)–(8) могут быть использованы для случая, когда происходит дообучение нейросетевых моделей на текущих результатах прямых измерений. Вместе перечисленные соотношения образуют унифицированный подход к оценке погрешности результатов косвенных измерений, получаемых с использованием средств искусственного интеллекта.

Библиография

1. Flores, T. K. S., Villanueva, J. M. M., Gomes, H. P., Catunda, S. Y. (2020). Indirect feedback measurement of flow in a water pumping network employing artificial intelligence. *Sensors*. Vol. 21(1). Paper 75.
2. Benabdesselam, A., Dollon, Q., Zemouri, R., Pelletier, F., Gagnon, M., Tahan, A. (2024). On the use of indirect measurements in virtual sensors for renewable energies: A review. *Electronics*. Vol. 13(8). Paper 1545.
3. Zhong, R., Xu, Y., Cao, Y., Guo, X., Hua, W., Xu, S., Sun, W. (2016). Accurate model of switched reluctance motor based on indirect measurement method and least square support vector machine. *IET Electric Power Applications*. Vol. 10(9). P. 916–922.
4. Maiorino, A., Del Duca, M.G., Tušek, J., Tomc, U., Kitanovski, A., Aprea, C. (2019). Evaluating magnetocaloric effect in magnetocaloric materials: a novel approach based on indirect measurements using artificial neural networks. *Energies*. Vol. 12(10). Paper 1871.
5. Zaman, Q., Alraho, S., König, A. (2020). Low-cost indirect measurement methods for self-x integrated sensory electronics for Industry 4.0. *tm-Technisches Messen*. Vol. 87(s1). P. s79–s84.
6. Kaverzneva, T., Lazovskaya, T., Tarkhov, D., Vasilyev, A. (2016). Neural network modeling of air pollution in tunnels according to indirect measurements. *Journal of Physics: Conference Series*. Vol. 772(1). Paper 012035.
7. Beckmann, M., Heilenkötter, N. (2024). Equivariant neural networks for indirect measurements. *SIAM Journal on Mathematics of Data Science*. Vol. 6(3). P. 579–601.
8. Gu, N., Wu, W., Guo, X., Peng, J. (2023). A novel residual improved deep learning indirect measurement algorithm (RIDLA) for nonlinear dynamic responses. *Mechanics Research Communications*. Vol. 129. Paper 104087.

9. Schiller, H. (2007). Model inversion by parameter fit using NN emulating the forward model – Evaluation of indirect measurements. *Neural networks*. Vol. 20(4). P. 479–483.

10. Dolenko, S., Isaev, I., Burikov, S., Dolenko, T., Obornev, E., Shimelevich, M. (2023). Methodology for Solving High-dimensional Multi-Parameter Inverse Problems of Indirect Measurements. *Proc. of the 16th International Conference on Pattern Recognition and Information Processing (PRIP'2023)*. Belarus, Minsk, October 17–19, 2023 (pp. 162–165).

11. Kopenkov, V. N., Sergeev, V. V., Timbai, E. I. (2011). Regression restoration methods as applied to solve the problem of multidimensional indirect measurements. *Pattern Recognition and Image Analysis*. Vol. 21. P. 501–504.

12. Halchenko, V.Y., Trembovetska, R., Tychkov, V. (2025). Indirect simultaneous eddy-current measurements of subsurface profiles of electrophysical properties in planar objects using a priori knowledge about them. *Metrology and Measurement Systems*. Vol. 32(1). P. 1–15.

13. Zhu, J., Wang, Z., Xia, X., Li, P. (2003). Approach for the evaluation of indirect measurement uncertainty based on neural networks. In *Fifth International Symposium on Instrumentation and Control Technology* (vol. 5253, pp. 303–308). SPIE.

14. Руководство по выражению неопределенности измерения. Пер. с англ. – СПб.: ВНИИМ им. Д.И. Менделеева, 1999.

15. Griewank, A. (1989). On Automatic Differentiation. In *Mathematical Programming: Recent Developments and Applications*. Mathematics and its Applications Series (MAJA, vol. 6, pp. 83–108). Kluwer Academic Publishers.

ESTIMATION OF ERROR IN INDIRECT MEASUREMENT RESULTS OBTAINED USING ARTIFICIAL INTELLIGENCE MEANS

Konstantin K. Semenov

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

semenov_kk@spbstu.ru

Abstract. The paper considers the problem of estimating the error in indirect measurement results obtained using artificial intelligence means. The modern state of development of neural network modelling technologies has led to their widespread – including indirect measurements in metrology. This paper provides

a review of applications of artificial neural networks presented in the literature for obtaining indirect measurement results. It discusses its error estimation considering the peculiarities of the problem related to the application of neural networks. The relations proposed in the paper are unified, do not depend on the type or structure of the involved neural networks and allow providing complete metrological support even for situations when neural networks retrain according to the current results.

Keywords. Indirect measurements, artificial neural networks, metrological support, transformed uncertainty

* * *

Секция 2.

«РАСПРЕДЕЛЕННЫЙ И ГИБРИДНЫЙ ГРУППОВОЙ ИНТЕЛЛЕКТ В РОБОТОТЕХНИКЕ»

УДК 004.023

doi:10.18720/SPBPU/2/id25-529

ИНТЕЛЛЕКТУАЛЬНАЯ ЭВРИСТИКА В ЗАДАЧЕ ПЛАНИРОВАНИЯ ДВИЖЕНИЯ РОБОТОТЕХНИЧЕСКИХ СИСТЕМ

Довгополик Илья Сергеевич¹, Борисов Олег Игоревич²

Университет ИТМО, Санкт-Петербург, Россия,

¹isdovgopolik@itmo.ru, ²borisov@itmo.ru

Аннотация. В работе рассматривается применение методов машинного обучения в задаче планирования пути робототехнических систем. Рассматриваются алгоритмы планирования на основе графов и применяемая для повышения эффективности эвристика выборки узлов графа. Проведён анализ возможных областей применения методов машинного обучения для улучшения работы алгоритмов на основе графов, рассмотрены существующие подходы с использованием ИИ в задачах обучения эвристик, определения направления поиска и использовании модели ИИ в качестве локального планировщика. Определены достоинства и недостатки существующих подходов поиска пути с ИИ для этих областей применения.

Ключевые слова: робототехнические системы, планирование пути, эвристика выборки, машинное обучение.

Введение

Планирование пути является ключевой задачей в робототехнике, основой выполнения практически любых операций [1,2]. Ос-

новной тренд в развитии алгоритмов поиска маршрута — это повышение эффективности работы алгоритмов при одновременном сохранении или повышении ресурсоэффективности [3]. Главные показатели работы алгоритма планирования — это время, длина пути, оптимальность пути по заданному критерию, процент успешных решений, энергоэффективность [1-5]. Под ресурсоэффективностью подразумевается эффективность использования ресурсов электронной вычислительной машины (ЭВМ), а именно памяти и вычислительной мощности [1-6]. Эффективным инструментом решения задачи планирования пути являются алгоритмы на основе графов. За счёт своей простоты и высокого быстродействия они являются одними из самых эффективных и универсальных подходов для нахождения безопасного пути как в простых статических пространствах (отсутствуют динамические препятствия, пространство не меняется с течением времени) так и в сложных динамических средах [7-8]. Важной особенностью алгоритмов на основе графов является использование эвристики выборки точек, которые присоединяются к графу в качестве узлов (вершин). Использование различных математических законов оценки точек пространства значительно повышает ключевые параметры работы алгоритмов поиска [9-10]. В последнее время очень активно развиваются алгоритмы машинного обучения, которые находят применение во многих сферах, в том числе и в робототехнике. В рамках задачи планирования пути с использованием алгоритмов на основе графов очень перспективным способом применения машинного обучения является синтез интеллектуальных эвристик выборки точек. Это позволяет выполнять сложный анализ точек в пространстве без усложнения алгоритма поиска пути большим количеством сложных математических проверок. Таким образом симбиоз классических подходов с методами машинного обучения является одним из самых перспективных направлений развития алгоритмов планирования пути робототехнических систем.

Алгоритмы планирования на основе графов. Этот класс алгоритмов содержит множество подходов, которые применяются для разнообразных задач, в том числе в промышленности, сервисной

робототехнике, сфере чрезвычайных ситуаций и др. Самыми распространёнными подходами являются алгоритм Дейкстры, A*, D* и D* Lite, LPA* (Lifelong Planning A*), Алгоритм Fringe Search, Алгоритм Theta*, Hybrid A*, RRT, PRM.

Алгоритм Дейкстры [10] представляет собой жадный алгоритм поиска кратчайшего пути, в котором на каждой итерации выбирается узел с минимальной текущей стоимостью пути от начальной точки. Он гарантирует оптимальность в графах с неотрицательными весами. Алгоритм находит основное применение в задачах с полной информацией о среде, например, при навигации в заранее известной карте помещения.

A* [11] улучшает алгоритм Дейкстры, дополняя его эвристической функцией $h(n)$, оценивающей предполагаемую стоимость пути от текущего узла до цели. Общая оценка задается формулой $f(n) = g(n) + h(n)$, где $g(n)$ — фактическая стоимость пути. Это позволяет значительно сократить количество рассмотренных узлов. При использовании эвристики выборки точек алгоритм сохраняет оптимальность. Находит широкое применение в мобильной робототехнике и навигации в двумерных и трёхмерных пространствах.

D* (Dynamic A*) [12] и его упрощённая версия **D* Lite** предназначены для динамически меняющихся или неизвестных пространств. Эти алгоритмы используют механизм повторного планирования при изменении карты — пересчитывают только затронутые участки графа, что делает их эффективными в реальном времени.

LPA* [13] предназначен для задач с частым планированием в среде, которая может незначительно меняться. Алгоритм сохраняет информацию о предыдущем пути, и на его основе выполняет пересчёт маршрута, что быстрее, чем полный запуск A*. Это делает его особенно полезным для роботов, оперирующих в нестатических помещениях, таких как фабрики или склады.

Fringe Search [14] — это итеративный алгоритм поиска, схожий с A*, но использующий жёсткое ограничение вместо очереди с приоритетами. Это позволяет значительно ускорить вычисления, особенно в больших графах. Тем не менее, он не гарантирует оптимальность пути и чувствителен к выбору эвристики.

Theta* [15] является расширением A^* . Позволяет искать не только пути вдоль рёбер графа, но и прямые траектории между узлами при наличии прямой видимости. Это обеспечивает более естественные, сглаженные пути по сравнению с A^* , что особенно важно для мобильных роботов и дронов.

Hybrid A^* [16] позволяет выполнять поиск алгоритмом A^* с учётом кинематических ограничений системы (например, радиуса поворота транспортного средства). Каждый узел представляет из себя не координаты в пространстве, а состояние системы, что позволяет генерировать физически осуществимые траектории. Этот метод широко используется в автономных транспортных средствах и других роботах с ограничениями управления.

RRT (Rapidly-exploring random tree) [17] строит дерево (граф) поиска, начиная с начального положения, и случайным образом исследует пространство состояний, постепенно расширяя дерево до достижения целевой точки или выполнения условия окончания поиска. Особенно эффективный в высокоразмерных и сложных по геометрии пространствах.

PRM (Probabilistic Roadmap Method) [18] — это один из классических вероятностных алгоритмов планирования пути, особенно эффективный для многократного поиска пути в одном и том же пространстве, например, при движении манипуляторов или мобильных роботов в известной статической среде.

Интеллектуальная эвристика на базе методов машинного обучения. Алгоритмы машинного обучения могут быть эффективно применены для следующих задач:

1. Обучение эвристик: вместо ручной настройки эвристических функций (например, евклидово расстояние в A^*) можно обучать нейросеть, которая предсказывает стоимость пути до цели на основе карты, истории и других признаков.

2. Управление выборкой в RRT/PRM: алгоритмы используют нейросеть для более «умной» выборки точек, ускоряя построение дерева и избегая тупиков. Также можно определять направление поиска в пространстве, чтобы не исследовать области, где путь точно не будет проложен.

3. Использование в качестве локального планировщика: с глобальным планировщиком PRM или RRT может быть применена обученная модель как локальный планировщик (соединяющий точки), что позволяет учитывать динамику и ограничения среды.

Обучение эвристик с помощью нейросетей. Классические алгоритмы поиска пути, такие как A^* , используют эвристическую функцию $h(n)$ для оценки стоимости достижения цели из узла n . Традиционно эвристика — это простая метрика, например, евклидово расстояние, не учитывающее сложность среды. Нейросети позволяют обучать более информативные эвристики, которые адаптируются под особенности конкретной карты и учитывают препятствия, динамические объекты. Примеры такого применения:

Value Iteration Networks (VIN) [19]. VIN — это архитектура нейросети, имитирующая классический алгоритм динамического программирования (value iteration) через сверточные слои. Модель обучается на примерах карт и целей, чтобы предсказывать стоимость достижения цели из любого состояния. Таким образом, VIN выступает как обучаемая эвристика, позволяющая A^* и другим алгоритмам эффективнее ориентироваться в пространстве.

Heuristic Learning for Graph Search (HLGS) [20]. HLGS применяет глубокие нейронные сети для обучения эвристических функций в графах с произвольной структурой. Сеть предсказывает приближённую стоимость пути от узла до цели, улучшая выбор при поиске A^* и сокращая количество посещённых узлов.

Deep Heuristic Search (DHS) [21]. Метод DHS сочетает классический поиск с нейросетью, которая оценивает перспективность узлов. Сеть обучается выделять области графа, которые более вероятно содержат оптимальный путь, направляя поиск.

Learning-based Heuristic Function (LBHF) [22]. LBHF — это подход, где эвристическая функция обучается на исторических данных о средах и маршрутах. Она способна адаптироваться к различным типам окружения, улучшая качество эвристики для задач планирования.

Преимущества:

- Улучшенная точность оценки стоимости, что ускоряет поиск.
- Возможность адаптации к сложным и динамичным средам.
- Снижение вычислительной нагрузки за счёт сокращения количества рассмотренных узлов.

Недостатки:

- Требуется большое количество обучающих данных или симуляций.
- Модель может плохо обобщать на сильно отличающиеся от обучающей среды.

Управление направлением поиска в RRT/PRM. В классических вероятностных алгоритмах, таких как RRT и PRM, точки выборки генерируются случайным образом, что может привести к неэффективному исследованию пространства, особенно при наличии узких проходов или сложной геометрии. Нейросети обучаются предсказывать более перспективные точки выборки, тем самым направляя рост графа. Современные алгоритмы, применяемые для решения этой задачи:

Adaptive RRT (ARRT) [23]. ARRT использует нейросети для обучения вероятностного распределения выборки точек в пространстве. Вместо равномерной случайной генерации в пространстве, точки появляются в «интересных» областях, например, узких проходах, что повышает эффективность и скорость планирования.

Learned Sampling-based Motion Planning (LSMP) [24]. В LSMP нейросеть обучается на данных предыдущих планирований, чтобы прогнозировать наиболее полезные точки выборки для RRT или PRM. Это позволяет значительно сократить число итераций и улучшить оптимальность построенных путей.

Motion Planning Networks (MPNet) [25]. MPNet — это энд-ту-энд нейросеть, обучаемая на демонстрациях и опыте, способная напрямую генерировать траектории обхода препятствий, заменяя собой этапы выборки и поиска. Это значительно ускоряет планирование в сложных средах.

Neural RRT (NeuralRRT) [26]. NeuralRRT комбинирует классический RRT с обучаемым компонентом, который выбирает на-

правления роста дерева, основываясь на опыте и анализе карты. Такая гибридизация улучшает производительность при сохранении гарантии нахождения решения.

Преимущества:

- Ускорение сходимости к цели.
- Более равномерное и целенаправленное исследование пространства.
- Уменьшение числа итераций и вычислительных затрат.

Недостатки:

- Необходимость предварительного обучения на репрезентативных данных.
- Возможное переобучение под конкретные классы задач.

Применение обученной модели в качестве локального планировщика. Локальный планировщик отвечает за проверку прямолинейного пути между точками, совокупность которых является путём в пространстве, полученным от глобального планировщика. Локальный планировщик должен учитывать препятствия и ограничения кинематики. Классические методы часто используют геометрическую проверку столкновений. В сложных динамических системах с ограничениями на управление и динамикой робота обучение моделей (например, нейросетей или RL-агентов) позволяет более точно предсказывать допустимые переходы, учитывая физику и ограничения. Примеры таких подходов:

Reinforcement Learning Local Planner (RL-LP) [27]. RL-LP — агент, созданный при помощи обучения с подкреплением, который выполняет локальное планирование, учитывая физические и кинематические ограничения робота. Агент самостоятельно учится избегать столкновений и строить управляемые траектории.

Deep Reinforcement Learning for Local Trajectory Planning (DRL-LTP) [29]. Этот метод использует глубокие нейросети, обучаемые на симуляциях или реальных данных, для локального построения траекторий. Обучение учитывает динамику робота и изменяющиеся условия среды, обеспечивая плавность и безопасность движения.

Neural Motion Planner (NMP) [28]. NMP заменяет классические алгоритмы локального планирования нейросетью, которая предсказывает траектории с учётом ограничений времени реакции и динамики. Модель может адаптироваться под новые условия среды и быстро реагировать на изменения.

Imitation Learning for Local Planning (IL-LP) [28]. IL-LP — подход, в котором нейросеть обучается повторять эталонные локальные траектории, построенные опытными операторами вручную или классическими оптимальными алгоритмами планирования пути. Это обеспечивает высокий уровень безопасности и эффективности движения робота.

Преимущества:

- Более реалистичные и управляемые траектории.
- Учет динамических и кинематических ограничений.
- Возможность адаптации к изменяющимся условиям среды.

Недостатки:

- Сложность обучения и необходимость моделирования физики.
- Высокие вычислительные затраты на обучение и интеграцию.

Заключение

Применение интеллектуальных эвристик на базе машинного обучения позволяет значительно повысить эффективность классических алгоритмов планирования на основе графов, а именно отсеять невостребованные узлы графа и ускоряет поиск, особенно в сложных и динамических средах. Использование ИИ для направленного поиска в пространстве позволяет вести его в более перспективных области пространства, что особенно важно при наличии узких проходов и сложной геометрии. Использование RL и нейросетей для локального планирования даёт возможность учитывать кинематические и динамические ограничения роботов, а также адаптироваться к изменяющейся среде в реальном времени. Алгоритмы планирования пути робототехнических систем,

которые являются синтезом классических алгоритмов и алгоритмов машинного обучения, показывают высокую эффективность при решении задачи поиска маршрута и являются ресурсоэффективными.

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации (проект № FSER-2025-0002) и НИРСИИ Университета ИТМО (проект №640112).

Библиография

1. Karur, K., Sharma, N., Dharmatti, C., & Siegel, J. E. (2021). A Survey of Path Planning Algorithms for Mobile Robots. *Vehicles*, 3(3), 448–468. DOI: 10.3390/vehicles3030027.
2. Jie, Y., Nguyen, T. T., Dao, T.-K., & Nguyen, T.-T. (2024). Global Path Planning Algorithm for Mobile Robots: A Review. *Journal of Network Intelligence*, 9(S2), 643–659.
3. Liu, H., Zhang, S., & Yang, X. (2023). Overview of Path Planning Algorithms. *Recent Advances in Computer Science and Communications*, 18(7), 1–14. DOI: 10.2174/1872212118666230828150857.
4. Choudhary, A. (2023). Sampling-based Path Planning Algorithms: A Survey. arXiv preprint arXiv:2304.14839. arXiv.
5. Gasparetto, A., Boscaroli, P., Lanzutti, A., & Vidoni, R. (2015). Path Planning and Trajectory Planning Algorithms: A General Overview. In *Motion and Operation Planning of Robotic Systems* (pp. 3–27). Springer. DOI: 10.1007/978-3-319-14705-5_1.
6. Siciliano, B., & Khatib, O. (Eds.) (2016). *Springer Handbook of Robotics* (2nd ed.). Springer. — 2220 с.
7. LaValle, S. M. (2006). *Planning Algorithms*. Cambridge University Press. — 846 с.
8. Thrun, S., Burgard, W., & Fox, D. (2005). *Probabilistic Robotics*. MIT Press. — 672 с.
9. Choset, H., Lynch, K. M., Hutchinson, S., Kantor, G., Burgard, W., Kavraki, L. E., & Thrun, S. (2005). *Principles of Robot Motion: Theory, Algorithms, and Implementations*. MIT Press. — 608 с.
10. Siegwart, R., Nourbakhsh, I. R., & Scaramuzza, D. (2011). *Introduction to Autonomous Mobile Robots* (2nd ed.). MIT Press. — 472 с.
11. Dijkstra, E. W. (1959). A note on two problems in connexion with graphs. *Numerische Mathematik*, 1(1), 269–271.

12. **Koenig, S., & Likhachev, M.** (2002). D* Lite. In Proceedings of the AAAI Conference on Artificial Intelligence (pp. 476–483).
13. **Koenig, S., & Likhachev, M.** (2004). Lifelong Planning A*. Artificial Intelligence, 155(1–2), 93–146.
14. **Björnsson, Y., Enzenberger, M., Holte, R. C., & Schaeffer, J.** (2005). Fringe Search: Beating A* at Pathfinding on Game Maps. In Proceedings of the IEEE Symposium on Computational Intelligence and Games (pp. 125–132).
15. **Nash, A., Koenig, S., & Tovey, C.** (2007). Theta*: Any-angle path planning on grids. In Proceedings of the AAAI Conference on Artificial Intelligence (pp. 1177–1183).
16. **Dolgov, D., Thrun, S., Montemerlo, M., & Diebel, J.** (2008). Practical search techniques in path planning for autonomous driving. In Proceedings of the First International Symposium on Search Techniques in Artificial Intelligence and Robotics (STAIR-08) (pp. 1–8).
17. **Tamar, G., Wu, Y., Thomas, G., Levine, S., & Abbeel, P.** (2016). Value iteration networks. Advances in Neural Information Processing Systems, 29, 2154–2162.
18. **Chen, Y., Chen, Z., & Yu, H.** (2020). Learning heuristics for fast planning in graphs. Proceedings of the 37th International Conference on Machine Learning (ICML), PMLR 119:1665–1674.
19. **Xie, L., Tang, Y., & Li, S.** (2018). Deep heuristic search. Proceedings of the AAAI Conference on Artificial Intelligence, 32(1).
20. **Huang, H., & Todorov, E.** (2017). Learning heuristic functions for search algorithms. Proceedings of the International Conference on Automated Planning and Scheduling (ICAPS).
21. **Ichter, B., Harrison, J., & Pavone, M.** (2018). Learning sampling distributions for robot motion planning. IEEE International Conference on Robotics and Automation (ICRA), 7087–7094.
22. **Qureshi, A. H., Pathak, S., & Lee, S.** (2019). Motion planning networks. Robotics: Science and Systems (RSS).
23. **Gammell, J. D., Srinivasa, S. S., & Barfoot, T. D.** (2015). Batch informed trees (BIT): Sampling-based optimal planning via the heuristically guided search of implicit random geometric graphs*. IEEE International Conference on Robotics and Automation (ICRA), 3067–3074.
24. **Ichter, B., Pavone, M., & Deisenroth, M. P.** (2020). Learning sampling distributions for robot motion planning: A review and future directions. IEEE Robotics and Automation Letters, 5(2), 456–463.
25. **Wurm, K. M., Hornung, A., & Bennewitz, M.** (2020). Learned local planning for mobile robots. Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 1234–1241.

26. **Pfeiffer, M., Schaeuble, M., Nieto, J., Siegwart, R., & Cadena, C.** (2018). Reinforced imitation: Sample efficient deep reinforcement learning for map-less navigation by leveraging prior demonstrations. IEEE International Conference on Robotics and Automation (ICRA), 1–8.
27. **Kretschmar, H., & Burgard, W.** (2019). Probabilistic motion planning with learned heuristics for autonomous driving. IEEE Transactions on Intelligent Transportation Systems, 21(5), 2143–2156.
28. **Tai, L., Paolo, G., & Liu, M.** (2017). Imitation learning for autonomous navigation in complex environments. IEEE Robotics and Automation Letters, 2(2), 1323–1330.

INTELLIGENT HEURISTICS IN THE TASK OF MOTION PLANNING OF ROBOTIC SYSTEMS

Ilya S. Dovgopolik¹, Oleg I. Borisov²

ITMO University, St. Petersburg, Russia

¹isdovgopolik@itmo.ru, ²borisov@itmo.ru

Abstract. The paper considers the application of machine learning methods in the problem of path planning for robotic systems. Graph-based planning algorithms and the heuristics of graph node selection are considered. An analysis of possible areas of application of machine learning methods to improve the performance of graph-based algorithms is carried out, existing approaches using AI in the problems of learning heuristics, determining the search direction, and using an AI model as a local planner are considered. The advantages and disadvantages of existing AI pathfinding approaches for these areas of application are determined.

Keywords. Robotics, path planning, sampling heuristics, machine learning.

* * *

ИНТЕЛЛЕКТУАЛЬНОЕ УПРАВЛЕНИЕ КОЛЛАБОРАТИВНЫМИ МОБИЛЬНЫМИ РОБОТАМИ В ЗАДАЧАХ ПРОМЫШЛЕННОЙ АВТОМАТИЗАЦИИ

Яременко Андрей Михайлович¹, Захаров Дмитрий Николаевич,
Панин Александр Дмитриевич, Алиев Дмитрий Романович,
Борисов Олег Игоревич

Университет ИТМО Санкт-Петербург, Россия

¹amyaremenko@itmo.ru

Аннотация. В данной работе представлен новый подход к разработке коллаборативных мобильных роботов, основанный на интеграции распределенной системы тензодатчиков непосредственно в конструкцию робота, что позволяет отказаться от использования манипулятора на борту. В отличие от традиционных мобильных манипуляторов, увеличивающих сложность системы и ограничивающих полезную нагрузку, предлагаемый метод обеспечивает взаимодействие человека и робота через прямой физический контакт с самой платформой. В работе предлагается использование распределенной системы датчиков, интегрированной в корпус платформы, в сочетании с контуром управления на основе адмитансного подхода и виртуальным механизмом безопасности, предотвращающим направление результирующих сил в сторону человека. Это позволяет роботу интерпретировать намерения человека и реагировать, обеспечивая безопасное взаимодействие. Экспериментальная валидация показала, что данный подход обеспечивает интуитивно понятное коллаборативное поведение в условиях промышленной эксплуатации.

Ключевые слова. Мобильная роботизированная платформа, коллаборативный робот, коллаборативность, промышленная безопасность, управление роботизированными системами, мехатроника, робототехника, всенаправленная платформа.

Введение

В настоящее время достижения в области искусственного интеллекта, сенсорных технологий и прецизионной механики стимулируют развитие современной робототехники. Однако согласно

отчетам Международной федерации робототехники (IFR) за 2024 год, средняя плотность роботов составляет всего 113 промышленных роботов на 10 000 сотрудников. Эти цифры указывают на тот факт, что текущий уровень технологий пока не позволяет обеспечить полную автономность роботов в неструктурированных средах [1]. Кроме того, человек, благодаря своим гибким когнитивным способностям все еще остается незаменимым во многих технологических операциях. Вместо того, чтобы рассматривать человека и машину независимо друг от друга, концепция Индустрии 4.0 предлагает модель синергитического взаимодействия, при которой автономный или полуавтономный робот дополняет человеческие навыки [2]. Коллаборативные роботы (коботы) являются воплощением этой парадигмы.

Согласно стандарту ISO 10218-1:2011, коллаборативный робот – это роботизированная система, работающая совместно с человеком и предназначена для безопасного физического взаимодействия. Существует множество работ, посвященных исследованиям взаимодействия робота и человека, но большинство из них сосредоточены на манипуляционных роботах. Решения для мобильных роботов достигаются за счет установки манипуляционных коллаборативных роботов [3,4].

Однако платформы с роботами – манипуляторами имеют следующие недостатки: возрастает размер мобильного робота, ограничивается полезная нагрузка, увеличивается стоимость робота. В работе [5] авторы предлагают размещать параллельные манипуляторы на группе всенаправленных роботов, благодаря чему человек может взаимодействовать с объемными и тяжелыми грузами. В работе [6] представлена методология обучения по демонстрации (Learning from Demonstration), основанная на методах машинного обучения и тактильной обратной связи от оператора-человека для совместной манипуляции объектом. В этом случае человек задаёт желаемую траекторию движения, а робот контролирует вес объекта. Согласование движение манипулятора достигается за счет использования набора сенсоров, а также алгоритма управления и обучения. Другой подход заключается в разработке манипуляторов, которые за счёт

своей конструкции изначально обладают гибкостью для безопасного взаимодействия с человеком. Исследования в области мягкой робототехники (soft robotics) активно развивают это направление. Несмотря на большое количество работ в данной области, применение манипуляционных роботов имеет существенный недостаток — все они являются стационарными системами с ограниченной рабочей зоной. Для преодоления этого ограничения некоторые исследователи предлагают использовать мобильного робота в качестве подвижной базы, а сам манипулятор — как систему обеспечения совместного взаимодействия с человеком. Так в работе [7] для обеспечения коллаборативности используются два манипулятора, установленных на мобильную платформу, а также предложен алгоритм управления нагрузкой совместно с роботом.

Такой подход накладывает серьезные ограничения при выполнении ряда задач. Стоимость кобота сопоставима со стоимостью автономной мобильной платформы, способной перевозить грузы массой 200–500 кг. Использование коботов в связке с колёсными платформами увеличивает габариты мобильного робота, ограничивает полезную нагрузку и занимает пространство, которое могло бы быть использовано для размещения груза — в результате мобильный робот становится ещё более сложной системой, в которой ключевая задача заключается в балансировке между функциональностью, ограничениями, безопасностью и энергоэффективностью при значительном росте стоимости. Все эти ограничения оказываются критичными, особенно для использования в задачах складской и промышленной логистики.

Постановка задачи

Описание предметной области. Один из методов интуитивного и естественного взаимодействия человека с роботом — использование силовой обратной связи [8]. Это объясняется тем, что простые физические действия, такие как толкание, являются естественными для человека [9]. Ранее описанные работы использовали манипуляционные роботы с их сенсорными и управляющими системами




Рис. 1. Схема коллаборативного управления

ми для достижения этой цели. В настоящей работе предлагается перенести этот привычный для человека подход на всенаправленного робота.

Общая схема предлагаемого решения представлена на рис. 1.

В качестве транспортной платформы используется всенаправленный робот, обеспечивающий голономное движение в плоскости за счёт применения всенаправленных колес. По периметру платформы в элементы корпуса интегрирована сенсорная система, обеспечивающая силовую обратную связь. Полученные данные фильтруются и обрабатываются с помощью алгоритма управления, ориентированного на безопасность. Он сочетает в себе адмитансное управление и метод виртуальных сил с ограничением по направлению приложенной силы.

Определение проблемы. Существуют различные подходы к управлению мобильным роботом, управляемым человеком, при

этом наиболее часто используются джойстик и голосовое управление. Однако в промышленных условиях эти подходы имеют существенные ограничения: голосовое управление часто ненадежно из-за высокого уровня шума, в то время как управление с помощью джойстика становится непрактичным при одновременном управлении несколькими роботами, поскольку требует индивидуального подключения и создает высокую когнитивную нагрузку на оператора. В качестве альтернативы было предложено силовое управление, предлагающее интуитивно понятный метод взаимодействия, который сводит к минимуму требования к обучению оператора и повышает безопасность при выполнении совместных задач. Благодаря адаптивному реагированию на прикладываемые оператором усилия, этот подход обеспечивает бесперебойную координацию между людьми и роботами, особенно при работе с грузами. Однако при направлении робота к потенциальным препятствиям необходимо убедиться, что результирующая сила, действующая на робота, не направлена на человека.

Моделирование системы

Алгоритм оцувствления платформы по внешней прикладываемой силе. Алгоритм состоит из двух основных компонентов. Первая часть отвечает за расчет воздействия, оказываемого человеком на робота, в то время как вторая часть имеет дело с воздействием препятствий. После этого общее воздействие вычисляется как сумма полученных компонентов. При таком расчете сил результирующая сила может оказаться противоположной силе, приложенной человеком. Целью совместного контроля является достижение следующих равновесных условий:

$$\begin{cases} \lim_{t \rightarrow \infty} F_x = 0; \\ \lim_{t \rightarrow \infty} F_y = 0; \\ \lim_{t \rightarrow \infty} M_z = 0, \end{cases} \quad (1)$$

где F_x, F_y, M_z представляют собой проекции сил и момента, действующих на робота со стороны человека.

Для второй части вводится следующее допущение: препятствия моделируются в виде полилиний. Согласно [9], виртуальная сила, создаваемая препятствием, может быть выражена в следующей форме:

$$\vec{F}_v = \begin{cases} k_d \vec{d} + k_v \vec{v}, & \text{если } |d| \leq d_0; \\ 0, & \text{если } |d| > d_0, \end{cases} \quad (2)$$

где $\vec{d}$ – вектор от ближайшей точки объекта (препятствия) до центра робота, а $\vec{v}$ – скорость робота в глобальной системе координат.

Учет безопасного перенаправления. В сценариях, связанных с движением с препятствиями, необходимо убедиться, что результирующая сила, действующая на робота, не направлена на человека. Обозначим через F_p силу, приложенную человеком, а через F_o суммарную силу, возникающую от препятствий. Тогда результирующая сила F_r выражается следующим образом:

$$F_r = F_p + F_o, \quad (3)$$

Для обеспечения безопасности угол θ между F_p и F_r должен удовлетворять:

$$\theta \notin [\pi - \delta, \pi + \delta], \quad (4)$$

где δ определяет запрещенный сектор движения в радианах. Если θ попадает в этот диапазон, необходимо отрегулировать результирующее усилие F_r . Скорректированное усилие F'_r рассчитывается следующим образом:

$$F'_r = \|F_r\| \hat{u}, \quad (5)$$

где $\|F_r\|$ – величина результирующей силы, а $\hat{u}$ – единичный вектор, соответствующий ближайшей границе запрещенного сектора и определяемый как:

$$\hat{u} = \begin{cases} \pi - \delta, & \text{если } \theta < \pi; \\ \pi + \delta, & \text{если } \theta \geq \pi, \end{cases} \quad (6)$$

Такая регулировка гарантирует, что движение робота будет соответствовать требованиям безопасности.

Заключение

В данной работе был предложен новый подход к коллаборативной мобильной робототехнике, интегрируя распределённую систему силового чувствования непосредственно во всенаправленную платформу. В отличие от традиционных мобильных манипуляторов, которые используют роботизированные руки для взаимодействия, описанный подход позволяет реализовать физическое взаимодействие человека и робота через непосредственный контакт с мобильной платформой.

Разработанная система управления сочетает в себе адмитансное управление с алгоритмом безопасности на основе виртуальных сил, что позволяет гарантировать, что результирующие силы не направлены в сторону человека. Экспериментальная валидация показала, что представленный подход обеспечивает интуитивное и безопасное взаимодействие при сохранении гибкости и маневренности платформы.

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации (проект № FSER-2025-0002) и НИРСИИ Университета ИТМО (проект № 640112).

Библиография

1. **D. Wang, J. Lin, L. Ma, D. Huang and Y. Wu.** “Image-based visual admittance control with prescribed performance of manipulators in feature space,” IEEE Transactions on Industrial Electronics, pp. 1–11, 2024.
2. **A. Weiss, A.-K. Wortmeier and B. Kubicek.** “Cobots in industry 4.0: A roadmap for future practice studies on human–robot collaboration,” IEEE Transactions on Human-Machine Systems, vol. 51, no. 4, pp. 335–345, 2021.
3. **B. Navarro, A. Cherubini, A. Fonte, G. Poisson and P. Fraisse.** “A framework for intuitive col-laboration with a mobile manipulator,” in 2017 IEEE/RSJ

International Conference on Intelligent Robots and Systems (IROS). IEEE, 2017, pp. 6293–6298.

4. **T. Kastritsi and A. Ajoudani.** “A Passive Power-Based Control Strategy for pHRI Tasks With Omni-Directional Robotic Mobile Platforms,” in IEEE Robotics and Automation Letters, vol. 9, no. 8, pp. 6959–6966, Aug. 2024, doi: 10.1109/LRA.2024.3415930.

5. **M. L. Elwin, B. Strong, R. A. Freeman and K. M. Lynch.** “Human-multirobot collaborative mobile manipulation: The omnidirectional mobile robots,” IEEE Robotics and Automation Letters, vol. 8, no. 1, pp. 376–383, 2022.

6. **Calinon, Sylvain & Evrard, Paul & Gribovskaya, Elena & Billard, Aude & Kheddar, Abderrahmane.** (2009). Learning collaborative manipulation tasks by demonstration using a haptic interface. 2009 International Conference on Advanced Robotics, ICAR 2009. 1 – 6.

7. **K. Kosuge, M. Sato and N. Kazamura.** “Mobile robot helper,” in Proceedings 2000 ICRA. Millennium conference. IEEE international conference on robotics and automation. Symposia proceedings (Cat. No. 00CH37065), vol. 1. IEEE, 2000, pp. 583–588.

8. **A. Blackler, S. Desai, M. McEwan, V. Popovic and S. Diefenbach.** “Perspectives on the nature of intuitive interaction,” Intuitive Interaction Research and Application, pp. 19–39, 2019.

9. **D. Engelbrecht, N. Steyn and K. Djouani.** “Adaptive virtual impedance control of a mobile multi-robot system,” Robotics, vol. 10, no. 1, p. 19, 2021.

INTELLIGENT CONTROL OF COLLABORATIVE MOBILE ROBOTS IN INDUSTRIAL AUTOMATION TASKS

**Andrey M. Yaremenko¹, Dmitry N. Zakharov, Alexandr D. Panin,
Dmitry R. Aliev, Oleg I. Borisov**

ITMO University, Saint-Petersburg, Russia

¹amyaremenko@itmo.ru

Abstract. This paper presents a novel approach to the development of collaborative mobile robots based on the integration of a distributed force sensor system directly into the robot’s structure, eliminating the need for an onboard manipulator. Unlike traditional mobile manipulators, which increase system complexity and limit payload capacity, the proposed method enables human-robot interaction through direct physical contact with the platform itself. The approach involves a distributed sensor system embedded in the robot’s body, combined with an admittance-based control loop and a virtual safety mechanism that prevents

resultant forces from being directed toward the human. This allows the robot to interpret human intent and respond accordingly, ensuring safe interaction. Experimental validation demonstrated that this approach enables intuitive and effective collaborative behavior in industrial environments.

Keywords. Mobile robotic platform, collaborative robot, collaborativity, industrial safety, robotic systems control, mechatronics, robotics, omnidirectional platform.

* * *

УДК 004.94

doi:10.18720/SPBPU/2/id25-531

ИТЕРАТИВНЫЙ МЕТОД ДЕЦЕНТРАЛИЗОВАННОГО УПРАВЛЕНИЯ ФОРМИРОВАНИЕМ РОЯ БПЛА

Курочкин Михаил Александрович¹, Тимофеев Александр Сергеевич²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹kurochkin.m@gmail.com, ²a.timoff3@gmail.com

Аннотация. В статье рассматривается задача формирования роя беспилотных летательных аппаратов (БПЛА) в трёхмерном пространстве при децентрализованном управлении. Предложен итеративный подход, основанный на модификации классического алгоритма Boids, расширяющий правила поведения БПЛА. В качестве вспомогательного этапа исследуются различные методы генерации конечных позиций роя, включая геометрические и стохастические стратегии. Представлены результаты численного моделирования, демонстрирующие сходимость метода.

Ключевые слова. БПЛА, рой, децентрализованное управление, роевой интеллект, алгоритм Boids, упаковка сфер, моделирование траекторий.

Введение

Беспилотные летательные аппараты (БПЛА) с каждым годом активно используются в разных сферах жизнедеятельности человека. Актуальность этого направления подчёркивается распоряжением правительства России [1]. К числу перспективных задач следует от-

нести разработку методов децентрализованного управления роем (группой) беспилотных летательных аппаратов. Практическая ценность полученных результатов будет полезна специалистам сельского хозяйства, МЧС, экстренным службам, в геодезии, логистике, сферы строительства. [2] Основным преимуществом децентрализованного подхода является высокая степень отказоустойчивости. Теоретической основой многих мультиагентных систем без явного лидера выступает роевой интеллект — концепция, которая описывает сложное групповое взаимодействия через простые локальные правила взаимодействия участников роя. В статье [3] система децентрализованного управления позволяет примерно в 3,5 раза уменьшить погрешность поддержания строя по сравнению с системой управления с лидером (централизованное управление).

В настоящей работе исследуются итеративный метод формирования роя БПЛА (дронов) при децентрализованном управлении.

Постановка задачи

Описание предметной области. Беспилотный летательный аппарат (БПЛА) — воздушное судно, выполняющее задачи без участия полета на борту. Типичная продолжительность полёта таких аппаратов составляет от десятков минут до нескольких суток.

Каждый БПЛА окружён собственной сферической зоной радиусом r_s , определяющей минимальное пространство, занимаемое аппаратом в воздухе. Обмен данными возможен только с соседними БПЛА, находящимися на расстоянии не более радиуса связи r_c . Формирование роя является предварительной задачей перед выполнением прикладных миссий. БПЛА или их группы могут стартовать из различных начальных позиций $\vec{s}$ и обладать различной максимальной скоростью. Целью является объединение всех аппаратов в единый рой за период времени $[0; T]$ в пределах окрестности заданной точки $\vec{W}$ радиусом R . Форма роя представляет собой правильную сферу, характеризующуюся плотностью z — числом БПЛА, которые могут быть размещены внутри данной области без пересечений.

Сравнение времени работы алгоритмов упаковки сфер

Алгоритм	Природа алгоритма	Число БПЛА	Среднее время работы (мс)
Fibonacci Sphere	Геометрический	10	3
HPC-packing	Геометрический	10	165
Random packing	Стохастический	10	2
Fibonacci Sphere	Геометрический	50	46
HPC-packing	Геометрический	50	206
Random packing	Стохастический	50	29

но в условиях, когда для каждой особи (агента) требуется заранее известная и стабильная конфигурация роя.

Формально задача допустимого множества конечных позиций дронов в рое имеет следующий вид:

$$|\hat{S}| \rightarrow Z. \quad (1)$$

$$\hat{S} = \{s_i \in R^3 \mid \|s_i - W\| \leq R, \forall i \neq j \mid \|s_i - s_j\| \geq 2r_s\}. \quad (2)$$

В табл. 1 приведено сравнение времени работы алгоритмов формирования конечных позиций дронов для роя $\tilde{S}$ со следующими параметрами (число запусков 1000): $W = \{0, 0, 0\}$; $R = 5$ м.; $r_s = 0,4$ м.; $Z = \{10, 50\}$;

Алгоритм плотной гексагональной упаковки (HPC-packing) позволяет построить наиболее плотную оболочку, однако при малом Z требует больше времени для вычислений. Стохастический подход случайной упаковки (Random packing) и упаковка с помощью сферы Фибоначчи выполняются за сравнительно одинаковое время, однако Fibonacci Sphere генерирует позиции более равномерно, чего трудно достичь при полностью стохастическом подходе.

Формальная постановка задачи. Дано:

1. $U = \{U_1, \dots, U_N\}$ — множество БПЛА.
2. S — рой со следующими параметрами:
 - а. $\vec{W} = \{W_x, W_y, W_z\}$ — координаты центра роя.
 - б. R — радиус оболочки (м).
 - с. Z — максимальное число БПЛА в оболочке роя.
3. T — время формирования роя.

Необходимо: для каждого $U_i, i=1, \dots, N$ построить траекторию движения из начальной точки $\vec{s}_i$ во внутреннюю область роя в интервале времени $[0; T]$.

Ограничения: при перемещении БПЛА исключить коллизии (коллизия — пересечение защитных оболочек БПЛА).

Для решение поставленной задачи выделим ряд подзадач:

1. Разработать метод заполнения оболочки сферы радиуса R с центром W равный плотности Z .
2. Разработать метод формирования роя БПЛА.
3. Провести апробацию разработанного решения.

Метод решения задачи

Формирование конечных позиций БПЛА. Генерация позиций конечных дронов в рое является начальным этапом формирования роя. Данная задача является подмножеством задач трёхмерной упаковки, относящимся к классу NP-полных задач [4]. В рамках исследования рассматриваются геометрические и стохастические эвристики. Геометрические методы основаны на итеративной генерации позиций с учетом некоторых геометрических правил. Эти методы отличаются четкой детерминированностью и повторяемой структурой роя. Стохастические подходы предполагают случайное начальное размещение с последующей итеративной пост обработкой, которая приводит случайные позиции в необходимое состояние. Для корректного выполнения полётного задания необходимо, чтобы конечные позиции агентов, полученные на этапе генерации, были воспроизводимы при повторных запусках. Это критич-




Рис. 1. Результат работы алгоритма Fibonacci Sphere и Random Packing

Основной идеей Fibonacci Sphere является генерация позиций, на отдельных радиусах (слоях) сферы:

$$\{R - r_s, R - 2r_s, \dots, R - 2kr_s\},$$

где число k — это число слоев внутри роя.

На рис. 1 показан результат генерации позиций с помощью алгоритмов Fibonacci Sphere и Random Packing.

С учетом ограничений, часто, на практике используется алгоритм Fibonacci Sphere, обеспечивающий детерминированную и локально воспроизводимую генерацию, что позволяет формировать рой с устойчивой геометрией.

Итеративный метод формирования роя:

Метод формирования роя основан на модели Boids, описывающей стайное поведение птиц или косяка рыб [5]:

- сепарация (отдаление соседей друг от друга);
- выравнивание (стремление лететь в одну сторону с соседями);
- когезия (сближение с центром массы позиции соседей).

Вышеперечисленные правила Boids для агента u_i , $i = 1, \dots, N$ формально можно представить следующим образом:

$$\vec{F}_{cohesion} = \left[\frac{1}{|N_i|} \sum_{j \in N_i} \vec{s}_j \right] - \vec{s}_i \quad (3)$$

где N_i — это множество соседей агента u_i , s_i — это позиция i -го агента.

$$\vec{F}_{separation} = \sum_{\{u' | u' \in N_i \cap \|s_i - s_j\| < d\}} \left(\frac{\vec{s}_i - \vec{s}_j}{\|\vec{s}_i - \vec{s}_j\|} \right) \quad (4)$$

где d — минимальное безопасное расстояние.

$$\vec{F}_{alignment} = \left[\frac{1}{|N_i|} \sum_{j \in N_i} \vec{v}_j \right] - \vec{v}_i \quad (5)$$

где v_i — это нормаль направления движения i -го агента.

Правила модели Boids расширены для решения поставленной задачи:

- притяжение к цели (агент стремится двигаться в сторону роя);

$$\vec{F}_{target} = \vec{t}_i - \vec{s}_i, \quad (6)$$

где t_i — это выбранная конечная позиция i -го агента.

- динамическое изменение скорости (агенту управляет своей скоростью в зависимости от окружающей среды);

- динамический выбор конечной позиции (агент может уступить соседу конечную точку если сосед доберется до нее быстрее).

Итоговое направление движения на шаге k задается следующим образом:

$$\vec{v}_i^k = \text{norm} \left(\sum_{j=1}^4 w_j \cdot \vec{F}_j \right) \quad (7)$$

где w_j — это весовой коэффициент из вектора $\vec{w}$ для правила F_j (учитывая, что правил всего 4).

Предлагаемая схема итеративного метода для заданных параметров задачи и дискретностью времени выглядит следующим образом:

1. Каждый БПЛА $u \in U$ выбирает ближайшую не занятую позицию в рое, с наименьшим расстоянием до W .
2. Выполнить расчет базовой траектории.
3. Начало движения:
 - a. Разрешить конфликты по выбору конечной точки с соседями.
 - b. Вычислить всех $u \in U$ с учетом формул (3–6).
 - c. Обновить скорость для всех $u \in U$.
 - d. Обновить позиции БПЛА с учетом τ и скорости агента.
 - e. Если БПЛА u достиг конечной точки, остановить его.
 - f. Сохранить координаты в пространстве всех БПЛА $u \in U$.

Эксперимент. Проведен численный эксперимент для исследования зависимости значений $\bar{w}$ на скорость сходимости решения. В качестве целевой функции оценки решения выбрано среднее расстояние всех БПЛА до конечной точки в рое. Описание эксперимента:

1. Значение $\bar{w} = \{(1, 1, 1, 1), (1, 0.5, 0.5, 0.5), (1, 2.5, 2.5, 2.5), (1, 1, 0, 0)\}$.
2. $N = 30$.
3. Параметры БПЛА: $v \sim U(15, 30)$; $\bar{s} \sim (U(0, 1000), U(0, 1000, 0))$; $r_s = 1$; $r_s = 100$.
4. Параметры роя: $W = (500, 500, 100)$; $Z = 30$; $R = 7$.
5. $T = [0; 100]$.

На рис. 2 приведен график средней ошибки решения за период времени.

В результате эксперимента наиболее быстрая сходимость решения была получена при использовании вектора $\bar{w} = (1, 0.25, 0.25, 0.25)$. Из зависимости также следует, что применение весовых коэффициентов позволяет уменьшить время формирования роя на 20 % по сравнению с классическим подходом в модели Boids.




Рис. 2. Зависимость времени и средней ошибки для разных значений вектора

Заключение

В результате работы разработан итеративный метод формирования роя БПЛА при децентрализованном управлении. Были исследованы алгоритмы генерации конечных позиций роя, основанные на стохастических и геометрических подходах.

Для реализации метода была дополнена модель Boids рядом новых поведенческих правил: таргетированием, динамическим выбором скорости и адаптивным выбором конечной позиции. Проведен численный эксперимент, позволивший сократить время формирования роя по сравнению с классическим подходом модели.

Библиография

1. Стратегия развития беспилотной авиации Российской Федерации на период до 2030 года и на перспективу до 2035 года / [Электронный ресурс] // Правительство России : [сайт]. — URL: <http://static.government.ru/media/files/3m4ANa9s3PrYTDr3l6ibUtyEVUpnRT2x.pdf> (дата обращения: 29.05.2025).
2. Создание «роя» из беспилотников и их возможное применение в различных сферах / М. А. Даньшин, В. М. Гурьянов, А. А. Подберезкин //

Интегрированные автоматизированные системы управления в отраслях транспортно-дорожного комплекса : Материалы 78-й научно-методической и научно-исследовательской конференции МАДИ, Москва, 27–31 января 2020 года. — Москва: Общество с ограниченной ответственностью «Техполиграфцентр», 2020. — С. 65–72.

3. В. Х. Пшихопов., М. Ю. Медведев. Сравнительный анализ централизованного и децентрализованного алгоритмов движения строем БЛА мультикоптерного типа. Известия Южного федерального университета. Технические науки, н. 1 (225), 2022. С. 121–139.

4. R. M'Hallah, A. Alkandari, N. Mladenovic. Packing unit spheres into the smallest sphere using VNS and NLP [Текст] / R. M'Hallah, A. Alkandari, N. Mladenovic, // Computers & Operations Research. — 2013. — № 40. — С. 603–615.

5. Reynolds C. W. Boids Background and Update / Reynolds C. W. [Электронный ресурс] // Craig Reynolds Homepage : [сайт]. — URL: <https://www.red3d.com/cwr/boids/> (дата обращения: 29.05.2025).

AN INTERACTIVE METHOD FOR DECENTRALIZED CONTROL OF UAV SWARM FORMATION

Mikhail A. Kurochkin¹, Alexandr S. Timofeev²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹kurochkin.m@gmail.com, ²a.timoff3@gmail.com

Abstract. The paper addresses the problem of UAV swarm formation in three-dimensional space under decentralized control. An iterative approach is proposed, based on a modified version of the classical Boids algorithm, extending the agents' behavioral rules. As a supporting step, various methods for generating final swarm positions are explored, including geometric and stochastic strategies. Numerical simulations are presented to demonstrate the convergence of the proposed method.

Keywords. UAV, swarm, decentralized control, swarm intelligence, Boids algorithm, sphere packing, trajectory modeling.

* * *

УДК 004.383.8

doi:10.18720/SPBPU/2/id25-532

КИБЕРИММУНИТЕТ В БЕСПИЛОТНЫХ АВИАЦИОННЫХ СИСТЕМАХ

Немчинов Артем Андреевич¹, Амелин Константин Сергеевич²,
Губарев Андрей Александрович³, Серохвостов Александр Юрьевич⁴,
Соболев Леонид Александрович⁵, Соболев Сергей Павлович⁶,
Чернов Андрей Олегович⁷

Санкт-Петербургский государственный университет,
Санкт-Петербург, Россия

¹artem.nemchinov@spbu.ru, ²k.amelin@spbu.ru, ³andrey.gubarev@spbu.ru,

⁴a.serokhvostov@spbu.ru, ⁵leonid.sobolev@spbu.ru, ⁶s.sobolev@spbu.ru,

⁷a.o.chernov@spbu.ru

Аннотация. В работе рассматривается возможность применения кибериммунного подхода в сфере беспилотных авиационных систем на примере разработки прототипа кибериммунного дрона-доставщика. Описаны цели и предположения безопасности кибериммунной БАС, представлена архитектура, использующая отдельные шаблоны из проекта ГОСТ Р «Защита информации. Системы с конструктивной информационной безопасностью. Методология разработки». Предложены аппаратные решения, позволяющие обеспечивать выполнение целей безопасности. Представлены результаты апробации кибериммунного подхода.

Ключевые слова. Кибериммунитет, БАС, конструктивная безопасность.

Введение

В последние несколько лет беспилотные авиационные системы (БАС) активно развиваются и применяются в поисково-спасательных работах [1], дистанционном зондировании земли [2], надзоре в строительной сфере [3], сельскохозяйственной деятельности [4], доставке товаров [5], мониторинге [6], обеспечении беспроводной связи [7].

Учитывая большое количество сфер применения беспилотников, вопрос защиты данных в этой отрасли является критичным.

Комплекс мер по обеспечению безопасности полетов должен включать в себя нормативно-правовое регулирование, операционную деятельность, конфиденциальность и защиту данных, технические и программные методы обеспечения безопасности; быть направлен на предотвращение аварий, минимизацию рисков для людей и инфраструктуры, а также защиту от возможных киберугроз.

В связи с этим существует проблема обеспечения благонадёжности функционирования БАС, его программного и аппаратного обеспечения на приемлемом для заинтересованных лиц уровне безопасности. Постановление Правительства РФ №1701 [8] ввело требования для обеспечения полетов БАС. Среди прочего были установлены требования по обеспечению наблюдаемости полета и его прерыванию по команде наземных диспетчерских систем.

Процесс самостоятельной разработки программ для контроля и управления БАС с нуля требует большого количества высококвалифицированных специалистов, ресурсозатрат и занимает длительное время. Использование готовых программ, сторонних библиотек и ПО с открытым исходным кодом позволяет значительно сократить ресурсозатраты, и время на разработку. Однако, при разработке программ с открытым исходным кодом отсутствует централизованная ответственность: над проектом работают специалисты различного уровня, некоторые из которых могут оказаться недостаточно квалифицированными или недобросовестными. Из-за этого в подобных программах могут возникать уязвимости — как возникшие случайно, так и умышленно размещенные вредоносные закладки, бэкдоры, скрытые каналы управления и другие функции, не предусмотренные документацией. Из-за перечисленных уязвимостей может быть осуществлен несанкционированный доступ к информации и данным, преднамеренное скрытое искажение частей алгоритмов программы, перехват, уничтожение, искажение или нарушение целостности данных, осуществление запрограммированных действий или бездействие при наступлении определенных событий.

Дополнительная проверка и верификация кода могла бы подтвердить безопасность стороннего решения. Однако, проведение такой работы представляется затруднительным из-за больших объемов и запутанной структуры кода. Более того, некоторые из перечисленных ранее уязвимостей могут относиться не только к программному, но и к аппаратному обеспечению.

Сейчас выбор применяемого ПО сводится к поиску баланса между полностью протестированным закрытым кодом собственной разработки, как правило с невысокой динамикой развития, или использованием быстроразвивающихся непроверенных элементов и библиотек, взятых из открытых источников, с высокими рисками для безопасности. Более того, сложные компоненты собственной разработки также могут содержать дефекты, появившиеся случайно или созданные намеренно. Они могут стать критическими уязвимостями. Одинаково тщательная разработка и верификация всей кодовой базы означает выделение значительных средств, которых у большинства компаний-разработчиков БАС в достаточном количестве не будет.

Решением описанной проблемы может стать кибериммунный подход [9]. Этот подход ранее был предложен для решений задачи по мониторингу оборудования [10] и для транспортных систем [11]. Более подробно методология разработки кибериммунных систем описывается в проекте ГОСТ Р «Системы с конструктивной информационной безопасностью» (СКИБ) [12].

Основная идея этого подхода состоит в том, что отдельные компоненты системы остаются уязвимыми и незащищенными. Вместо этого усилия прилагаются для предотвращения нежелательных событий и ситуаций, приводящих к критическому ущербу для пользователя системы. Допустимые условия работы системы описываются целями безопасности (ЦБ), выполнение которых и будет обеспечивать кибериммунная система.

Методика кибериммунной разработки развивает принципы кибербезопасности, делая акцент на конструктивную информационную безопасность. В зависимости от поставленных целей безопасности применяются шаблоны проектирования СКИБ, реали-

зуются механизмы изоляции и контроля взаимодействия доменов безопасности, выявляется критичный для целей безопасности код, который разрабатывается особо тщательным образом. Закладываются также дополнительные аппаратные механизмы, помогающие обеспечить защиту ключевых активов в ситуации как внешних, так и внутренних атак.

Предполагается, что стоимость успешной кибератаки на такую систему должна превышать стоимость потенциального ущерба.

Создание прототипа

Для апробации кибериммунного подхода в БАС рассматривается система для решения задачи по доставке груза автономным беспилотным квадрокоптером. Основным требованием к квадрокоптеру-доставщику является обеспечение сохранности груза. При этом доставщик должен оставаться безопасным для окружающих людей, критической инфраструктуры и имущества третьих лиц.

По аналогии с пилотируемой авиацией предлагается добавить имитатор системы организации воздушного движения (ИОрВД), которая будет осуществлять мониторинг полетов квадрокоптеров-доставщиков, а также авторизовывать все выполняемые задания по доставке. Обязательным условием для этой системы является высокий уровень доверия, для чего ее операторы должны обладать защищенными учетными записями для авторизации и высоким уровнем квалификации.

Для разрабатываемого прототипа эти требования были формализованы в виде следующих целей безопасности:

- 1) выполняются только аутентичные полетные задания;
- 2) выполняются только авторизованные системой ИОрВД задания, при этом статус авторизации может быть изменен в процессе выполнения задания;
- 3) все операции, включая выгрузку груза, выполняются согласно ограничениям в полетном задании;
- 4) в случае критического отказа дрон снижается вертикально со скоростью не более 1 м/с;

5) для запроса авторизации вылета к системе ИОрВД используется только аутентичный идентификатор дрона.

Важным условием для работы всей системы является наличие транспортных коридоров, обеспечивающих возможность беспилотнику на протяжении всего маршрута осуществить аварийную посадку без причинения неприемлемого ущерба.

На основе перечисленных ранее условий, необходимых для работы системы, были сформированы следующие предположения безопасности:

- 1) аутентичная система ИОрВД благонадёжна;
- 2) аутентичные сотрудники благонадёжны и обладают необходимой квалификацией;
- 3) только авторизованные сотрудники управляют ИОрВД;
- 4) аутентичное полетное задание составлено так, что на всем маршруте дрон может совершить аварийную посадку без причинения неприемлемого ущерба.

Исходя из заявленных целей и предположений безопасности, с учетом постановления Правительства [8] и проекта ГОСТ [12] был спроектирован прототип кибериммунного дрона-доставщика (ПКАДД). К архитектуре классической БАС, представленной на рис. 1, были применены отдельные шаблоны проектирования, описанные в методологии по разработке систем с конструктивной информационной безопасностью. К БАС был добавлен программно-аппаратный модуль безопасности (МБ), расширяющий ее архитектуру и функциональные возможности. Модифицированная архитектура представлена на рис. 2.

Все компоненты системы классифицированы на доверенные и недоверенные. Основным доверенным элементом кибериммунного БАС является модуль безопасности — программно-аппаратный компонент, осуществляющий мониторинг выполнения миссии, соблюдения требований и целей безопасности. Он позволяет осуществлять дополнительный контроль за рядом исполнительных устройств и отправлять корректирующие команды в модуль автопилота. Программная часть модуля безопасности выполняется на одноплатном микрокомпьютере Raspberry Pi 4, работаю-




Рис. 1. Высокоуровневая архитектура классической БАС

ций под управлением ОС KasperskyOS. Небольшой по объему код модуля безопасности может быть верифицирован без особых затрат ресурсов и времени, при этом обеспечить соблюдение целей безопасности.

Предполагается, что открытое ПО автопилота может быть скомпрометировано или содержать критические ошибки. Вследствие этого, никакие данные получаемые от него не могут считаться доверенными. Поэтому для модуля безопасности были продублированы приемник глобальных навигационных спутниковых систем (ГНСС) и барометр. Эти устройства считаются доверенными. Они позволяют модулю безопасности определять местоположение БАС, что необходимо для успешного осуществления контроля за исполнением миссии.

Связь модуля безопасности с сервером ИОрВД осуществляется через сеть Интернет. Из-за этого несмотря на то, что сервер ИОрВД является доверенным компонентом системы, необходима проверка подлинности поступающих от него команд и информа-

ции. Для этого используется подпись всех сообщений алгоритмом с открытым ключом. В прототипе дрона-доставщика для подписи используется алгоритм RSA [13].

В случае обнаружения отклонения БАС от аутентичного полетного задания, модуль безопасности может попытаться подать в полетный контроллер корректирующие команды. Однако, этого может оказаться недостаточно, например, в случае взлома БАС. В таком случае модуль безопасности должен аварийно прервать полет, отключив двигатели квадрокоптера. Это возможно благодаря разработанной плате аварийного отключения питания приводов моторов.

Аппаратное решение, kill-switch, представляет собой устройство на силовых транзисторах для коммутации мощной нагрузки. Принцип действия устройства заключается в размыкании плюсовой шины питания при программной активации аварийного режима. Плата предоставляет возможность экстренного программно-управляемого прекращения работы двигателей при помощи цифрового сигнала от модуля безопасности. Необходимости использования радиоканала управления нет, что повышает уровень безопасности при эксплуатации БАС в автономном режиме.




Рис. 2. Высокоуровневая архитектура кибериммунной БАС

Модуль активируется двумя разноименными сигналами (высокого и низкого уровня), что позволяет предотвратить запуск БАС при выходе из строя модуля безопасности.

Для обеспечения сохранности доставляемого груза и исключения возможности его преждевременной выгрузки, было разработано реле отключения питания сервопривода замка грузового отсека. Плата разработана по аналогии с платой аварийного отключения питания приводов моторов. Она представляет собой основанную на силовом транзисторе цепь для коммутации токов меньшей нагрузки. В случае поступления управляющего сигнала от модуля безопасности, реле замыкает плюсовую шину питания привода замка грузового отсека, предотвращая его открытие.

Разработанная платформа ПКАДД является открытой. Программный код модуля безопасности доступен в репозитории [14]. Чертежи, принципиальные схемы и инструкция по сборке доступны в репозитории [15].

Тестирование и апробация

Тестирование платформы ПКАДД и кибериммунного подхода к разработке ПО осуществлялось в виде инженерных соревнований по кибериммунной автономности в рамках проектно-образовательного интенсива «Архипелаг 2024».

Задачей студенческих команд, принимавших участие в соревновании, являлась разработка алгоритма для обеспечения безопасной и автономной доставки груза по предложенной трассе. Программное обеспечение автопилота квадрокоптера-доставщика содержало вредоносный код, срабатывавший в определенных местах трассы и приводивший к изменению миссии и потенциальному нарушению целей безопасности.

Для осуществления контроля прохождения маршрута модуль безопасности имел в своем распоряжении данные от модуля ГНСС и барометра, аутентичную миссию, полученную от сервера ИОрВД и возможность управлять платой аварийного отключения

питания моторов и сервопривода замка грузового отсека, а также пытаться корректировать выполняемые автопилотом команды.

Многие участники успешно справились с поставленной задачей и прошли трассу, не нарушив цели безопасности, несмотря на наличие закладок в ПО автопилота. Это является наглядной демонстрацией состоятельности применения кибериммунного подхода в сфере БАС.

Соревнования на «Архипелаге 2024» проводились в открытой полетной зоне, размером 40 м x 50 м x 8 м. Для позиционирования использовалась ГНСС. Однако, ГНСС обладает значительным количеством возможных источников появления ошибок при вычислении точного местоположения. К ним относятся погрешности в часах спутника, собственные шумы приемника, ионосферные задержки, переотражение сигнала, ограниченная область приема в условиях плотной городской застройки [16].

Использование ГНСС при проведении соревнований также влечет необходимость полета на открытом пространстве и, соответственно, необходимость получения у местной администрации разрешения на использование воздушного пространства для осуществления полетов. Для решения этой проблемы было предложено использовать локальную навигацию, что не только значительно увеличило бы точность позиционирования, но и упростило бы поиск площадки для проведения дальнейших соревнований, перенеся их в закрытое помещение меньшего размера.

Для локальной навигации была выбрана система компании «ПИРС», основанная на методе разницы во времени получения сигнала и использующая сверхширокополосные сигналы [16]. В прототип на программном и аппаратном уровне был интегрирован приемник системы локальной навигации, при этом алгоритмы контроля маршрута разработанные ранее сохранили свою работоспособность.

Повторные испытания проводились в виде регионального этапа инженерных соревнований по кибериммунной автономности в Москве в апреле 2025 года. Эти соревнования показали возмож-

ность использования кибериммунного БАС с системами локальной навигации в радиозакрытых помещениях в условиях ограниченного пространства.

Заключение

Для апробации кибериммунного подхода в сфере БАС была спроектирована и разработана платформа ПКАДД. Тестирование, проведенное в рамках инженерных соревнований, продемонстрировало, что кибериммунная БАС при выполнении предположений безопасности способна обеспечить выполнение всех целей безопасности, несмотря на использование ПО с открытым исходным кодом, содержащее в себе потенциальные уязвимости, приводящие к кибератакам.

В качестве дальнейшего развития кибериммунного направления предлагается тестирование данного подхода в наземных и водных транспортных системах, а также создание группового межсредового взаимодействия.

Библиография

1. **Silvagni M., Tonoli A., Zenerino E., Chiaberge M.** Multipurpose UAV for search and rescue operations in mountain avalanche events // *Geomatics, Natural Hazards Risk*. — 2017. — Т. 8. — № 1. — С. 18–33.
2. **Quaritsch M., Kruggl K., Wischounig-Struel D., Bhattacharya S., Shah M., Rinner B.** Networked UAVs as aerial sensor network for disaster management applications // *Elektrotech. Inftech*. — 2010. — Т. 127. — № 3. — С. 56–63.
3. **Аврунев Е. И., Дубровский А. В., Малыгина О. И., Никитин В. Н.** Разработка лабораторно-практической работы по применению современных средств сбора кадастровой информации с использованием беспилотных авиасистем // *Актуальные вопросы образования*. — 2018. — № 1. — С. 249–254.
4. **Марченко Л. А., Артюшин А. А., Смирнов И. Г., Мочкова Т. В., Спиридонов А. Ю., Курбанов Р. К.** Технология внесения пестицидов и удобрений беспилотными летательными аппаратами в цифровом сельском хозяйстве // *Сельскохозяйственные машины и технологии*. — 2019. — Т. 13. — № 5. — С. 38–45.

5. **Howell C., Jones F., Thorson T., Grube R., Joyce L., Coggin J., Kennedy J.** The first government sanctioned delivery of medical supplies by remotely controlled unmanned aerial system (UAS) // *NASA Technical Reports*. — 2016.

6. **Амелин К. С., Граничин О. Н.** Применение мультиагентного подхода для решения задач мониторинга местности группой легких БПЛА // *Теория активных систем. Труды международной научно-практической конференции*. — 2011. — Т. 3. — С. 209–214.

7. **Bupe P., Haddad R., Rios-Gutierrez F.** Relief and emergency communication network based on an autonomous decentralized UAV clustering network // *SoutheastCon*. — 2015. — С. 1–8.

8. Постановление Правительства Российской Федерации от 30.11.2024 № 1701. URL: <http://publication.pravo.gov.ru/document/0001202412030025>

9. **Духвалов А. П.** Кибериммунитет = ключ к безопасному цифровому миру будущего // *Проектирование будущего. Проблемы цифровой реальности*. — 2024. — Т. 7. — № 1. — С. 154–162.

10. **Соболев С. П.** Кибериммунный подход к разработке. Иллюстрация применения на базе микросервисной архитектуры // *Вестник СПбГУ. Прикладная математика. Информатика. Процессы управления*. — 2024. — Т. 20. — № 1. — С. 52–61.

11. **Логинава Л. Н., Домашкин А. Д.** Применение принципов кибериммунитета для обеспечения безопасности в транспортных системах // *Интеллектуальные транспортные системы*. — 2024. — С. 645–649.

12. Проект национального стандарта ГОСТ Р Защита информации. Системы с конструктивной информационной безопасностью. Методология разработки. 2025 URL: <https://fstec.ru/tk-362/standarty/proekty/proekt-natsionalnogo-standarta-gost-r-13>

13. **Rivest R. L., Shamir A., Adleman L.** A method for obtaining digital signatures and public-key cryptosystems // *Communications of the ACM*. — 1978. — Т. 21. — № 2. — С. 120–126.

14. Кибериммунный автономный квадрокоптер. — 2024. URL: <https://gitflic.ru/project/learning-cyberimmunity/cyberimmune-systems-autonomous-delivery-drone-with-kos>

15. Кибериммунный автономный квадрокоптер. Подборка материалов для сборки кибериммунного квадрокоптера. — 2024. URL: <https://gitflic.ru/project/learning-cyberimmunity/cyberimmune-systems-autonomous-delivery-drone-with-kos-hardware>

16. **Пудловский В. Б., Малышев А. П., Чугунов А. А., Серов С. А., Черных С. В.** Фильтрационный алгоритм оценки координат автомобиля в городе по сигналам ГНСС и сверхширокополосным сигналам локальной навигационной системы // *Успехи современной радиоэлектроники*. — 2024. — Т. 78. — № 1. — С. 64–77.

CYBER IMMUNITY IN UNMANNED AIRCRAFT SYSTEMS

Artem A. Nemchinov¹, Konstantin S. Amelin², Andrey A. Gubarev³,
Aleksandr Uy. Serokhvostov⁴, Leonid A. Sobolev⁵, Sergey P. Sobolev⁶,
Andrey O. Chernov⁷

Saint Petersburg State University, St. Petersburg, Russia

¹artem.nemchinov@spbu.ru, ²k.amelin@spbu.ru, ³andrey.gubarev@spbu.ru,

⁴a.serokhvostov@spbu.ru, ⁵leonid.sobolev@spbu.ru, ⁶s.sobolev@spbu.ru,

⁷a.o.chernov@spbu.ru

Abstract. The paper explores the feasibility of a cyber-immune approach application to unmanned aerial vehicles, using the development of a cyber-immune delivery drone prototype as an example. The safety goals and assumptions for a cyber-immune UAS are described. An architecture that utilizes specific patterns from the GOST R project “Information Protection. Systems with Constructive Information Security. Development Methodology” is presented. Hardware components that help to fulfill the safety goals are described. The results of the cyber immune approach testing are presented.

Keywords. Cyber immunity, UAV, security by design.

* * *

УДК 004.896

doi:10.18720/SPBPU/2/id25-533

УПРАВЛЕНИЕ МОБИЛЬНЫМ РОБОТОМ НА БАЗЕ АЛГОРИТМА TD3 С ОЦЕНКОЙ ВЕРОЯТНОСТНОГО ПРЕДСТАВЛЕНИЯ СОСТОЯНИЯ ДЛЯ ЧАСТИЧНО НАБЛЮДАЕМОЙ ОКРУЖАЮЩЕЙ СРЕДЫ

Бархум Мажд¹, Живицкий Андрей Юрьевич², Борисов Олег Игоревич³,
Пыркин Антон Александрович⁴

Университет ИТМО, Санкт-Петербург, Россия

¹tmow132@gmail.com, ²zhivitskii@itmo.ru, ³borisov@itmo.ru, ⁴pyrkin@itmo.ru

Аннотация. Работа посвящена проблеме навигации мобильных роботов в частично наблюдаемых средах, где неопределенность состояния существенно влияет на производительность. Мы предлагаем новый

подход, сочетающий алгоритм обучения с подкреплением Twin Delayed Deep Deterministic Policy Gradient (TD3) с оценкой вероятностного представления состояния. Эта интегрированная структура обеспечивает автономную навигацию в сложных средах за счет учета неопределенности состояния. Результаты моделирования демонстрируют повышенную эффективность по сравнению с исходным алгоритмом TD3.

Ключевые слова. Мобильные роботы, обучение с подкреплением, автономная навигация, оценка состояния, глубокое обучение.

Введение

В последние годы наблюдается рост применения мобильных роботов в различных сферах, включая промышленную автоматизацию и логистику. Однако ключевой проблемой, ограничивающей их широкое внедрение, остается обеспечение надежной навигации в условиях неопределенностей и неполной наблюдаемости окружающей среды. Это обуславливает необходимость разработки новых алгоритмических решений, способных эффективно функционировать в вышеупомянутых условиях. Обучение с подкреплением (Reinforcement Learning, RL) демонстрирует высокую эффективность в задачах навигации, однако традиционные методы RL [1-4] и более поздние методы глубокого обучения с подкреплением (Deep Reinforcement Learning, DRL) [5-8] предполагают полную наблюдаемость пространства состояний, что требует использования высокоточных сенсоров или дополнительных модулей предобработки данных. Интеграция отдельных модулей оценки состояния для RL-моделей может приводить к субоптимальному поведению, поскольку неопределенность среды не учитывается непосредственно в процессе обучения политики. Существующие подходы к решению проблемы частичной наблюдаемости, в которых оценка состояния интегрирована в процесс обучения с подкреплением, сталкиваются с трудностями при поддержании и обновлении оценок вероятностного представления состояний системы [9-10]. Это связано с высокой вычислительной сложностью одновременного обучения политики и обновления состояний, что может приводить к формированию неоптимальных стратегий. В данной работе

предложена унифицированная архитектура, сочетающая алгоритм TD3 (Twin Delayed Deep Deterministic Policy Gradient) с оценкой вероятностного представления состояний, что позволяет моделировать представление о состоянии робота и окружающей среды. Такой подход обеспечивает обучение политик, которые явно учитывают неопределенность и неполноту данных в процессе принятия решений.

Постановка задачи

Описание предметной области. Проблема навигации мобильного робота в недетерминированной среде формулируется как частично наблюдаемый марковский процесс принятия решений (POMDP). POMDP формализуется в виде 7-элементного кортежа $(\mathcal{S}, \mathcal{A}, \mathcal{P}, \mathcal{O}, \mathcal{R}, \gamma,)$, где $\mathcal{S}$ — множество возможных состояний среды; $\mathcal{A}$ — множество действий агента; $\mathcal{P}(s' | s, a)$ — вероятность перехода в состояние s' при выполнении действия a в состоянии s ; $\mathcal{O}$ — множество возможных наблюдений; $\mathcal{O}(o | s', a)$ — вероятность получения наблюдения o после перехода в s' с действием a ; $\mathcal{R}(s, a, s')$ — функция вознаграждения за переход из s в s' при действии a ; $\gamma \in [0, 1)$ — коэффициент дисконтирования будущих наград. В рамках данной модели агент формирует вероятностное представление о состоянии (belief state), вычисляя распределение вероятностей по множеству возможных состояний на основе истории действий и сенсорных данных на каждом шаге алгоритма.

По мере того, как методы RL становятся надежным методом управления автономными роботами, возникла необходимость преодоления ограничений существующих алгоритмов, что привело к разработке новых подходов, таких как актор-критик (actor-critic) архитектуры, для задач, требующих оптимальной политики в непрерывном пространстве действий. Алгоритмы, включая Deep Deterministic Policy Gradient (DDPG), Advantage Actor-Critic (A2C) и Soft Actor-Critic (SAC), получили широкое распространение в робототехнике. В этих методах актор (политика) π_θ выбирает действие на основе текущего состояния, а критик Q_ϕ оценивает

пару «состояние-действие». Алгоритм TD3 (Twin Delayed Deep Deterministic Policy Gradient) был предложен для устранения недостатков классических актор-критик архитектур, таких как переоценка значений функции ценности и высокая дисперсия оценок. TD3 включает три ключевых улучшения:

- Двойной критик с клиппингом (clipping): используются две Q -сети (Q_{ϕ_1}, Q_{ϕ_2}) , для обновления политики выбирается минимальная оценка: $y_t^{TD3} = r_t + \gamma \min_{i=1,2} Q_{\phi_i}(s_{t+1}, \pi_{\theta'}(s_{t+1}))$, что снижает смещение переоценки.

- Отложенные обновления политики: актор обновляется реже, чем критик, для стабилизации обучения: $\theta \leftarrow \theta + \alpha \nabla_\theta J(\theta)$, где $J(\theta)$ — функция стоимости актора.

- Сглаживание целевой политики: в действия добавляется ограниченный шум для уменьшения переобучения: $\tilde{a} = \pi_{\theta'}(s_{t+1}) + \epsilon$, $\epsilon \sim \text{clip}(N(0, \sigma), -c, c)$, обновление критиков выполняется минимизацией среднеквадратичной ошибки: $L(\phi_i) = \mathbb{E}_{(s,a,r,s')} \left[\left(Q_{\phi_i}(s,a) - y_t^{TD3} \right)^2 \right]$, $i \in 1, 2$, актор оптимизируется по детерминированному градиенту политики: $\nabla_\theta J(\theta) = \mathbb{E}_{s \sim D} \left[\nabla_a Q_{\phi_i}(s,a) \Big|_{a=\pi_{\theta}(s)} \nabla_\theta \pi_\theta(s) \right]$.

Определение проблемы. Существующие подходы к оценке вероятностного представления состояний в POMDP часто используют RNN/LSTM слои, встроенные отдельно в актор и критик, что приводит к принципиальной проблеме: политика и функция стоимости основываются на различных представлениях о состоянии системы. Это противоречит теоретическим основам POMDP, где единое вероятностное представление состояния должно служить основой для всех решений.

В данной работе мы устраняем этот недостаток путем введения выделенного модуля оценки вероятностного представления состояния на основе LSTM, общего для актора и критика, и механизма согласованного обучения через целевую сеть с мягкими обновлениями.

Моделирование системы управления

Оценка вероятностного представления состояния. Единая архитектура нейронной сети характеризуется отдельной сетью для оценки вероятностного представления состояния $\hat{B}_{s'}$, получающей на вход последовательность из 10 наблюдений $O_t = [o_1, o_1, \dots, o_{10}]^T$ и полярные координаты цели $[d_g, \theta_g]$. На выходе формируется двумерный вектор, состоящий из оценки истории действий и текущего наблюдения.

Архитектура TD3 представлена на рис. 1.

Обучение осуществляется посредством минимизации квадратичной функции ошибки:

$$L_B = \mathbb{E} \left[\left(\hat{B}_{s'} - s' \right)^2 \right]. \quad (1)$$

Архитектура сети для оценки $\hat{B}_{s'}$ показана на рис. 2.

Трехуровневая структура включает в себя полносвязный слой для нелинейного преобразования признаков, LSTM-слой для временных зависимостей и выходной слой с предсказанием $\hat{B}_t \in \mathbb{R}^2$. Архитектура дополнена механизмом обучения с мягкими обновлениями:

$$\phi' \leftarrow \tau\phi + (1-\tau)\phi' \quad (2)$$

$$\theta' \leftarrow \tau\theta + (1-\tau)\theta' \quad (3)$$




Рис. 1. Архитектура TD3 с выделенной сетью оценки. Состояние робота включает только полярные координаты цели




Рис. 2. Сеть оценки вероятностного представления состояний

Основываясь на уравнениях (2) и (3), введена целевая сеть оценки с мягкими обновлениями

$$\psi' \leftarrow \tau\psi + (1-\tau)\psi'.$$

Введена композитная функция потерь:

$$L_{(B-total)} = L_B + \mathbb{E} \left[\left(\hat{B}_{s'} - \hat{B}_{s'}^* \right)^2 \right],$$

где $\hat{B}_{s'}$ — целевое вероятностное представление состояния следующего состояния. В итоге, как видно из алгоритма (1), в процессе обучения задействована вся архитектура целиком. При обучении необходимо заморозить некоторые параметры. Так во время обучения актора, замораживаются параметры критика, а во время обучения оценщика замораживаются параметры и актора и критика.

Функции вознаграждения. Для того чтобы робот выбирал наиболее близкую к оптимальной стратегию навигации, в качестве функции вознаграждения выберем функцию

$$r = \begin{cases} r_g, & \text{если цель достигнута;} \\ r_{col}, & \text{если обнаружено столкновение;} \\ r_p + r_m + r_r + r_o + r_c & \text{иначе,} \end{cases}$$

где r_g, r_{col} — награды за достижение цели и штраф за столкновение, соответственно; $r_p = \frac{d_t - d_{t-1}}{2}$ — награда при движении в направлении цели, рассчитываемая как половина разницы дистанции до цели на каждом шагу; $r_m = \frac{v}{2}$ — награда за движение, помогающая исключить нахождение на месте; v — линейная скорость робота; $r_r = \frac{\omega}{2}$ — штраф за вращательные движения, обеспечивающий гладкость траектории; ω — угловая скорость; $r_o = \cos \Delta\theta$ — награда за направление в сторону цели; r_c — половина минимальной дистанции до препятствия.

Обучение и тестирование модели. Обучение моделей проводится в симуляционной среде, так как обучение на реальных роботах может быть дорогостоящим в случае их повреждения. Поэтому, как только алгоритм демонстрирует эффективность в симуляции, можно начинать процесс переноса на реального робота. Для обучения использовались Robot Operating System (ROS 2.0) и симулятор Gazebo, а также среду обучения, предложенную [11], где применяется мобильный робот Pioneer 3-DX с пространством действий $\mathbf{v} = [0, 1]$, $\mathbf{w} = [-1, 1]$. Выбор этой среды обусловлен стратегией обучения: при каждом сбросе среды рандомизируются не только позиция цели и робота, но и положение объектов.

Робот использует лазерный сканер на 180° для наблюдения за окружением на каждом шаге, и эти наблюдения (o_t) добавляются в буфер истории. Когда буфер заполняется, данные ($o_{t-1}, r_t, a_{t-1}, o_t, s_t, done$) записываются в буфер воспроизведения, после чего самое старое наблюдение удаляется. Флаг «done» означает завершение эпизода (достижение цели или столкновение). Награда за цель: +110, за столкновение: -100, в остальных случаях — по формуле (4). Обучение разделено на этапы: первые 500 итераций — награда за движение (r_m, r_n) с учетом расстояния до препятствий, затем 500 итераций — награда за приближение к цели (r_p) а далее — награда за ориентацию (r_o, r_r). Параметры обучения:

- Шум исследования: {0,1; 0.9}.
- Затухание шума: 2×10^5 шагов.
- Длина эпизода: 500 шагов.
- Шум политики: 0,2.
- Размер буфера воспроизведения: 10^6 .

Для тестовой среды мы инициализируем робота с обученным алгоритмом в простом мире, в котором присутствуют цилиндрические препятствия и имитация картонных коробок, положение которых случайным образом меняется при каждом запуске среды. Дополнительно мы создали более сложную, сильно загроможденную среду для оценки производительности в условиях высокой плотности препятствий. Задается последовательность из пяти целей, которые робот должен достичь поочередно. После достижения всех целей симуляция завершается.

Чтобы продемонстрировать эффективность предложенного алгоритма, мы сравнили наш алгоритм с роботом, обученным на стандартном TD3 (с сетями того же размера), на одной и той же последовательности из 5 целей, расположенных рядом с препятствиями. Мы замерыли время выполнения для обоих алгоритмов, чтобы оценить, насколько модифицированный TD3 превосходит оригинальный MDP подход.

Для статистической достоверности мы сохраняли генератор случайных чисел и провели 3 эксперимента, чтобы вычислить среднее время достижения всех целей. Результаты для обеих сред представлены в табл. 1.

Таблица 1

Сравнение времени достижения цели

Алгоритм	Цель 1, сек	Цель 2, сек	Цель 3, сек	Цель 4, сек	Цель 5, сек
Среда 1 (простая сцена)					
TD3	8,86	20,92	36,23	49,54	65,38
Наш алгоритм	6,84	17,99	32,48	46,50	59,57
Среда 2 (сложная, загроможденная сцена)					
TD3	8,66	12,45	14,69	24,47	32,72
Наш алгоритм	7,14	12,65	15,74	19,69	29,14




Рис. 3. Процесс производства дефектоскопа

В среднем, разработанный алгоритм показал лучшие результаты, чем оригинальный TD3. Наблюдая за симуляцией и сравнивая траектории на рис. 3, можно заметить, что робот на стандартном TD3 тратил больше времени на принятие решений вблизи препятствий, тогда как наш алгоритм обеспечивал более плавные и быстрые траектории движения к целям. Даже в более сложных, незнакомых средах наш алгоритм работает как минимум не хуже оригинального TD3, что подтверждает отсутствие переобучения сети оценки вероятностного представления на тренировочных данных.

Заключение

В работе было изучено применение модифицированного алгоритма TD3 с сетью оценки вероятностного представления состояния для навигации в частично наблюдаемых средах. Построены модели обучения с усиленной функцией вознаграждения и проверены в симулированных условиях, включая ранее неизвестные роботу сценарии. Сделаны выводы о преимуществах предложенного подхода перед стандартным TD3, а также обозначены направления для дальнейшего улучшения: внедрение дополнительных поведений (например, движение назад в тупиках), оптимизация архитектуры (использование

GeLU/Swish), интеграция визуальной информации с камеры. Перспективным шагом является валидация метода на реальном роботе.

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации (проект № FSER-2025-0002) и НИРСИИ Университета ИТМО (проект №640112).

Библиография

1. Bonin-Font, F., Ortiz, A., and Oliver, G. (2008). Visual navigation for mobile robots: A survey. *Journal of intelligent and robotic systems*, 53, 263–296.
2. Filliat, D. and Meyer, J. A. (2003). Map-based navigation in mobile robots: I. a review of localization strategies. *Cognitive Systems Research*, 4(4), 243–282.
3. Hoy, M., Matveev, A. S. and Savkin, A. V. (2015). Algorithms for collision-free navigation of mobile robots in complex cluttered environments: a survey. *Robotica*, 33(3), 463–497.
4. Nakhaeinia, D., Tang, S. H., Noor, S. M. and Motlagh, O. (2011). A review of control architectures for autonomous navigation of mobile robots. *International Journal of the Physical Sciences*, 6(2), 169–174.
5. Choi, J., Dance, C., Kim, J.e., Park, K.s., Han, J., Seo, J. and Kim, M. (2020). Fast adaptation of deep reinforcement learning-based navigation skills to human preference. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 3363–3370.
6. Han, S.H., Choi, H.J., Benz, P. and Loaiciga, J. (2018). Sensor-based mobile robot navigation via deep reinforcement learning. In *2018 IEEE International Conference on Big Data and Smart Computing (BigComp)*, 147154.
7. Jiang, H., Wang, H., Yau, W. Y. and Wan, K. W. (2020). A brief survey: Deep reinforcement learning in mobile robot navigation. In *2020 15th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, 592597. IEEE.
8. Zhu, K. and Zhang, T. (2021). Deep reinforcement learning based mobile robot navigation: A review. *Tsinghua Science and Technology*, 26(5), 674–691.
9. Dobrevski, M. and Skočaj, D. (2021). Deep reinforcement learning for map-less goal-driven robot navigation. *International Journal of Advanced Robotic Systems*, 18(1), 1729881421992621.
10. Meng, L., Gorbet, R. and Kulić, D. (2021). Memorybased deep reinforcement learning for pomdps. In *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 5619–5626.
11. Cimurs, R., Lee, J. H. and Suh, I. H. (2020). Goal-oriented obstacle avoidance with deep reinforcement learning in continuous action space. *Electronics*, 9(3).

A TD3-POWERED CONTROL OF MOBILE ROBOT WITH BELIEF STATE ESTIMATION FOR PARTIALLY OBSERVABLE DOMAINS

Majd Barhoum¹, Andrey Yu. Zhivitskii², Oleg I. Borisov³, Anton A. Pyrkin⁴

ITMO University, Saint-Petersburg, Russia

¹tmow132@gmail.com, ²zhivitskii@itmo.ru,

³borisov@itmo.ru, ⁴pyrkin@itmo.ru

Abstract. This work addresses the challenge of mobile robot navigation in partially observable environments, where state uncertainty significantly impacts performance. We propose a novel approach combining Twin Delayed Deep Deterministic Policy Gradient (TD3) reinforcement learning algorithm with explicit belief state estimation. This integrated framework enables autonomous navigation in complex environments by explicitly accounting for state uncertainty. Simulation results demonstrate improvements compared to the original Twin Delayed Deep Deterministic Policy Gradient (TD3) algorithm.

Keywords. Mobile robots, reinforcement learning, autonomous navigation, state estimation, deep learning.

* * *

УДК 004.021

doi:10.18720/SPBPU/2/id25-534

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ДЛЯ ОБНАРУЖЕНИЯ ИСТОЧНИКА ПОЖАРА С БОРТА БПЛА

Зорин Василий Александрович

Институт проблем управления им. В. А. Трапезникова

Российской академии наук, Москва, Россия

v.a.zorin@mail.ru

Аннотация. Использование нейросетевых алгоритмов в беспилотных летательных аппаратах (БПЛА) для раннего обнаружения источника пожара в режиме реального времени имеет важное значение для минимизации рисков распространения пожара и возможного причиненного ущерба. При этом применение алгоритмов требует соблюдения баланса между быстротой действия и рациональным использованием вычислитель-

ных ресурсов на борту БПЛА, включая параметры энергопотребления. В статье приведен обзор решений на основе нейросетевых алгоритмов, с учетом скорости работы и точности обнаружения, а также учитывается их размер, влияющий на энергопотребление. Выводы статьи дают представление о компромиссах между точностью, скоростью и размерами нейросетевых моделей, что позволяет сделать взвешенный выбор по рациональному использованию моделей в задачах обнаружения источника пожара с борта БПЛА и задел для дальнейших исследований.

Ключевые слова. Нейросетевые алгоритмы, БПЛА, обнаружение источника пожара.

Введение

Неконтролируемые возгорания именуемые пожарами угрожают экосистемам и человеческой жизни, в связи с чем раннее обнаружение становится критически важным для эффективной борьбы и профилактики. Дистанционные технологии обнаружения с применением БПЛА и с использованием нейросетевых моделей находят все большее применение в противопожарной работе. В этом исследовании приведен обзор нейросетевых алгоритмов, обеспечивающих необходимую скорость, точность работы, а также разумное энергопотребление при решении задач на борту БПЛА по раннему обнаружению источника пожара.

Существующие нейросетевые алгоритмы для обнаружения источника пожара

Для составления общей картины развития нейросетевых алгоритмов рассмотрим некоторые исследования по обнаружению источников пожара.

В статье [1] рассмотрено разнообразие нейросетевых алгоритмов, пригодных для применения в БПЛА для задач обнаружения источника пожара. При этом выбор подходящего алгоритма часто зависит от требований к точности и скорости обработки. Для обеспечения высокой точности применяются двухступенчатые детекторы, на основе региональных сверточных нейросетей, таких как

Faster R-CNN, а для обеспечения высокой скорости обработки более предпочтительными являются одноступенчатые детекторы, например такие как семейство YOLO, которые нашли широкое применение для использования на борту БПЛА. В случаях нехватки данных эффективнее оказываются методы, сочетающие глубокое обучение с корреляционной фильтрацией.

В целях более рационального использования ресурсов БПЛА, используются подходы по снижению потока данных до уровня, достаточного для детекции источника пожара и снижение параметров модели, для снижения затрат на вычисления. Исследование [2] по снижению потока данных с улучшением качества при помощи семантической сегментации с расстоянием Евклида-Махаланобиса и с семейством нейронных сетей YOLO экспериментально подтвердило возможность удаления лишней информации и повышения точности обнаружения пожара и дыма примерно на 11%, с задержкой всего 0,03 с. Быстродействующий алгоритм на базе алгоритмов семейства YOLO используется в автоматизированной системе раннего предупреждения о лесных пожарах [3].

Алгоритмы, основанные на YOLOv3 для обнаружения лесных пожаров с использованием данных, собранных с БПЛА [4], включают параллельную детекцию объектов малого пламени по набору соответствующих признаков, что позволяет повысить точность распознавания огня и снизить частоту ошибок. Исследован подход с использованием методов компьютерного зрения, где алгоритм К-ближайшего соседа обеспечивает точность обнаружения в 98,4%, а алгоритм случайного леса (Random Forest) в 99,6% [5]. Использование архитектуры CNN с элементами сети LSTM [6] обеспечивает высокие показатели точности в задачах обнаружения дыма с использованием методов машинного обучения, основанных на особенностях движения, прозрачности, цвете, форме, текстуре и фрактальных характеристиках.

Гибридный подход [7] для использования в системе раннего обнаружения пожаров, архитектура которого состоит из четырех нейросетевых моделей, каждая из которых вносит свой уникальный вклад: YOLOv10 обеспечивает быструю и грубую локализа-

цию; Mask R-CNN обеспечивает точную сегментацию на уровне пикселей; ConvLSTM-FireNet фиксирует временную динамику, такую как мерцание пламени; и DenseNet повышает надежность классификации при различном освещении. Совместная работа моделей повышает точность всей системы за счет взаимодополняющих сильных сторон. Гибридный каскад достиг самой высокой точности в автономном режиме среди всех конфигураций, с результатом 96,7%.

Однако размер модели составляет более 15 Мб и затраты на вычисления позволяют применять такой каскад скорее в наземных роботизированных системах, чем на борту БПЛА.

Методы с рациональным использованием вычислительных ресурсов

Рассмотренные исследования нейросетевых алгоритмов, направлены на повышение точности обнаружения источника пожара с борта БПЛА, однако вопрос уменьшения размера выходных параметров для рационального использования вычислительных ресурсов не раскрыт в полной мере.

Обратим внимание на метод обнаружения пожара, основанный на сверточных нейросетях (CNN) с архитектурой MobileNetV3 [8], в котором достигнута точность 90,2%, при размере модели 21 Мб.

Уменьшенная модель распознавания источников пожара реализована с использованием MobileNetV3 [9] при количестве параметров 2,64 миллиона, что на 95,87% меньше по сравнению с YOLOv4. Подход показывает преимущества модели с меньшим количеством параметров, низкими требованиями к памяти и высокой скоростью вывода по сравнению с существующими алгоритмами. Приведенный метод был специально разработан для использования в качестве системы мониторинга на борту БПЛА, при этом размер модели по оценке из другого источника [10] составляет 5,4 Мб.

Исследование легковесных нейросетевых алгоритмов [11] предлагает заменить YOLOv4 на MobileNetV3. Результаты эксперимен-

тов показали, что количество параметров в предлагаемой архитектуре уменьшается на 62,78%, а выходная скорость увеличивается в 3,04 раза по сравнению с YOLOv4 при точности обнаружения 66,6%, что позволяет реализовать способ обнаружения источника пожара с борта БПЛА в режиме реального времени на устройствах с низкими вычислительными ресурсами или сопоставимой экономией аккумуляторной батареи.

Эволюция семейства YOLO позволила достичь высокой производительности при минимизации параметров в целях обнаружения источника пожара с борта БПЛА с рациональным использованием вычислительных ресурсов при использовании метода на основе алгоритма YOLOv8 [12], в котором существующий модуль C2f был заменен на модуль упрощенный C2f-F. Эксперимент показал точность метода 98,4%, а размер модели всего 2,9 МБ, что обеспечивает баланс точности и количества параметров, а также энергопотребление на вычисления.

В статье [13] представлена уточненная итерация алгоритма для решения проблем точности обнаружения. MobileNetV3, основанный на модуле эффективного внимания к каналу (ECA — Efficient Channel Attention), используется в качестве магистральной сети модели, который позволяет снизить количество параметров на 43%. Модель оптимизируется с помощью метода обрезки ядра свертки. Основная идея обрезки (pruning) ядра свертки заключается в вычислении функции потерь всей модели и определении важности каждого слоя. В соответствии с важностью каждого слоя, малозначительные параметры обрезаются по очереди. В результате размер модели снижается до 1,2 Мб. Уменьшенная модель достигает показателей скорости 49 кадров в секунду (FPS) на Jetson AGX Xavier и точности обнаружения 79,8%.

В работе [14] предлагается сверхлегкая сеть YOLO-ULNet (Ultra Light Net) для обнаружения источника пожара на встроенных сенсорных устройствах. Первоначально легкая сеть YOLO-LNet была разработана для уменьшения количества параметров и снижения затрат на вычисления, размер которой составляет 0,26 Мб, точность и скорость 77,75% и 14,39 кадров в секунду, соответственно.

Применение методов обрезки каналов и сжатия позволили получить сверхлёгкую сеть YOLO-ULNet размером 0,19 Мб. Результаты тестирования YOLO-ULNet на одноплатном компьютере Raspberry Pi 4B показали, что точность и скорость достигли 74,50% и 24,57 кадров в секунду, что вполне соответствует требованиям обнаружения пожаров в режиме реального времени.

Способы снижения энергопотребления нейросетевых алгоритмов

Высокое энергопотребление сверточных нейронных сетей (CNN) связано с высокой вычислительной сложностью, что накладывает ограничение на применение в БПЛА, для которых энергопотребление является немаловажным фактором. Существуют исследования, которые стремятся уменьшить размер модели или объем вычислений, при этом результаты не обязательно приводят к снижению энергопотребления на вычисления. Чтобы сократить разрыв между проектированием нейросетевых алгоритмов и оптимизацией энергопотребления, предложен алгоритм обрезки с учетом энергии, который непосредственно использует оценку энергопотребления [15]. Методология оценки энергии использует параметры, экстраполированные из фактических аппаратных измерений, которые нацелены на реалистичные настройки системы с питанием от аккумуляторной батареи. Предлагаемый алгоритм обрезки по слоям обрезает более агрессивно, чем ранее предложенные методы обрезки, в результате реализации которых энергопотребление сетей AlexNet и GoogLeNet было снижено в 3,7 и 1,6 раза соответственно, с потерей точности менее 1%.

Сравнение размеров и архитектуры нейросетевых алгоритмов

Обрезка нейросетей (Pruning) стала эффективным решением для ускорения вычислений и снижения энергопотребления на небольших устройствах. Суть любой обрезки заключается в создании компактной модели из существующей модели большего размера. Существуют различные стратегии и методы обрезки нейронных

Таблица 1

Сводный анализ нейросетевых алгоритмов и их размеров

№ п/п	Алгоритм	Размер, Мб	Доступный уровень обрезки
1	LeNet	0,43	Вес/Фильтр/Нейрон
2	AlexNet	61,00	Вес/Фильтр
3	VGG-16	138,35	Вес/Фильтр/Нейрон/Слой
4	VGG-19	143,66	Вес/Фильтр
5	ResNet-18	11,69	Вес/Фильтр
6	ResNet-34	21,90	Вес/Фильтр
7	ResNet-56	0,85	Вес/Фильтр/Блок
8	ResNet-110	1,73	Вес/Фильтр/Блок
9	ResNet-152	60,19	Вес/Фильтр/Блок
10	DenseNet-40	1,04	Вес/Фильтр
11	DenseNet-121	8,06	Вес/Фильтр
12	MobileNet-V1	4,2	Вес/Фильтр
13	MobileNet-V2	3,4	Вес/Фильтр
14	MobileNet-V3	5,4	Вес/Фильтр
15	MobileNet-V3_ECA	1,2	Вес/Фильтр
16	GoogleNet	6,15	Вес/Фильтр/Ветвь
17	EfficientNet-B0	5,3	Вес/Фильтр
18	EfficientNet-B1	7,8	Вес/Фильтр
19	YOLOv4	63	Вес/Фильтр
20	YOLOv5s	7,07	Вес/Фильтр
21	YOLOv7	37,2	Вес/Фильтр
22	YOLO-LNet	0,26	Вес/Фильтр
23	YOLO-ULNet	0,19	Вес/Фильтр
24	YOLOv8 (C2f-F)	2,9	Вес/Фильтр
25	UNet	32	Вес/Фильтр

сетей, которые затрагивают разные уровни, в настоящей работе детально не рассматриваются. Для наглядности представления в таблицу сведены некоторые нейросетевые алгоритмы в соответствии с их и размерам и доступными уровнями обрезки (pruning) для уменьшения модели.

Заключение

В статье рассмотрены существующие нейросетевые алгоритмы, пригодные к применению на борту БПЛА для задач обнаружения источника пожара, включая обеспечение необходимой скорости вычислений, точности обнаружения, а также их размер, влияющий на энергопотребление вычислений. Приведены основные подходы по уменьшению размеров нейросетей, рассмотрены некоторые методы обрезки (pruning). Выводы статьи дают представление о размерах существующих нейросетевых моделей, которые непосредственно влияют на энергопотребление и дают задел для дальнейших исследований в части поиска баланса и эффективности.

Библиография

1. Зорин В. А., Мещеряков Р. В. Аналитический обзор нейросетевых алгоритмов обнаружения возгораний при чрезвычайных ситуациях // Вестник ЮУрГУ. Серия: Математика. Механика. Физика. 2025. Том 17, № 2. С. 23–34.
2. Abramov, N.; Emelyanova, Y.; Fralenko, V.; Khachumov, V.; Khachumov, M.; Shustova, M.; Talalaev, A. Intelligent Methods for Forest Fire Detection Using Unmanned Aerial Vehicles. Fire 2024, 7, 89. doi: 10.3390/fire7030089
3. Goyal S. et al. A yolo based technique for early forest fire detection //Int. J. Innov. Technol. Explor. Eng. – 2020. – Т. 9. – С. 1357–1362.
4. Wang Z. et al. A study on forest flame recognition of UAV based on yolo-v3 improved algorithm //Recent Advances in Sustainable Energy and Intelligent Systems: 7th International Conference on Life System Modeling and Simulation, LSMS 2021 and 7th International Conference on Intelligent Computing for Sustainable Energy and Environment, ICSEE 2021, Hangzhou, China, October 22–24, 2021, Proceedings, Part II 7. – Springer Singapore, 2021. – С. 497–503.

5. **Pradeep Kumar G., Rahul R., Ravindharan N.** Early Forest Fire Detection Using Machine Learning Algorithms //Int. J. New Technol. Res. – 2021. – Т. 7. – С. 1-5.

6. **Favorskaya M. N.** Early smoke detection in outdoor space: state-of-the-art, challenges and methods //Advances in Selected Artificial Intelligence Areas: World Outstanding Women in Artificial Intelligence. – Cham : Springer International Publishing, 2022. – С. 171–208.

7. **Sucuoglu, H. S.** Development of Real-Time Fire Detection Robotic System with Hybrid-Cascade Machine Learning Detection Structure. Processes 2025, 13, 1712. doi: 10.3390/pr13061712.

8. **Li Y.** et al. A visualized fire detection method based on convolutional neural network beyond anchor //Applied Intelligence. – 2022. – Т. 52. – № 11. – С. 13280–13295.

9. **Wang S.** et al. A real-time deep learning forest fire monitoring algorithm based on an improved Pruned+ KD model //Journal of Real-Time Image Processing. – 2021. – Т. 18. – №. 6. – С. 2319-2329

10. **Tmamna, J., Ayed, E. B., Fourati, R.** et al. Pruning Deep Neural Networks for Green Energy-Efficient Models: A Survey. Cogn Comput 16, 2931–2952 (2024). doi: 10.1007/s12559-024-10313-0

11. **Wang S.** et al. Forest fire detection based on lightweight Yolo //2021 33rd Chinese Control and Decision Conference (CCDC). – IEEE, 2021. – С. 1560–1565.

12. **L. Mu, Y. Yang, Y. Zhang, X. Xue** and **N. Feng.** A Lightweight Forest Fire Detection Method based on UAV Dual-modal Images, in IEEE Geoscience and Remote Sensing Letters, doi: 10.1109/LGRS.2025.3580564.

13. **Yang Y, Song P, Wang Y, Cao L.** Re-Parameterization After Pruning: Lightweight Algorithm Based on UAV Remote Sensing Target Detection. Sensors (Basel). 2024 Dec 2;24(23):7711. doi: 10.3390/s24237711. PMID: 39686248; PMCID: PMC11644868.

14. **L. Huang** et al., YOLO-ULNet: Ultralightweight Network for Real-Time Detection of Forest Fire on Embedded Sensing Devices, in IEEE Sensors Journal, vol. 24, no. 15, pp. 25175–25185, 1 Aug.1, 2024, doi: 10.1109/JSEN.2024.3416548

15. **Yang, Tien-Ju & Chen, Yu-Hsin & Sze, Vivienne.** (2016). Designing Energy-Efficient Convolutional Neural Networks using Energy-Aware Pruning. 10.48550/arXiv.1611.05128.

USING NEURAL NETWORK ALGORITHMS TO DETECT A FIRE SOURCE FROM BOARD A UAV

Vasilii A. Zorin

V. A. Trapeznikov Institute of Control Sciences
of the Russian Academy of Sciences, Moscow, Russia

v.a.zorin@mail.ru

Abstract. The use of neural network algorithms in unmanned aerial vehicles (UAVs) for early detection of a fire source in real time is important for minimizing the risks of fire spread and possible damage. At the same time, the use of algorithms requires maintaining a balance between performance and rational use of resources on board the UAV, including energy consumption parameters. The article provides an overview of solutions based on neural network algorithms, taking into account the speed of operation and detection accuracy, and also takes into account their size, which affects energy consumption. The conclusions of the article provide an idea of the compromise between the accuracy, speed and size of neural network models, which allows you to make a balanced choice on the rational use of models in the problems of detecting a fire source from on board a UAV and a reserve for further research.

Keywords. Neural network algorithms, UAVs, fire source detection.

* * *

УДК 330.1

doi:10.18720/SPBPU/2/id25-535

АВТОМАТИЗИРОВАННАЯ СИСТЕМА КОНТРОЛЯ ЗАГРУЗКИ ГРУЗОВОГО ТРАНСПОРТА ДЛЯ ГОРНО-ОБОГАТИТЕЛЬНЫХ КОМБИНАТОВ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИЙ КОМПЬЮТЕРНОГО ЗРЕНИЯ, В ТОМ ЧИСЛЕ ЛИДАРНЫХ ТЕХНОЛОГИЙ

Чайников Юрий Сергеевич

Московский авиационный институт, Москва, Россия

gutorin@gmail.com

Аннотация. Описана функциональность и результаты внедрения отечественной программной платформы, зарегистрированной в Едином реестре российского ПО (регистрационная запись № 1807028), предна-

значенной для интеллектуального анализа и адаптивного управления технологическими процессами в промышленности. Ключевым элементом системы является модуль детектирования в кадре объекта грузового транспорта, его распознавания и классификации объектов (борта кузова/вагона, дно, насыпь) на основе глубоких нейронных сетей.

Ключевые слова. Промышленный искусственный интеллект, контроль загрузки транспорта, определение негабаритных объектов, лидарные технологии, нейронные сети.

Введение

Современные горно-обогатительные комбинаты (ГОК) все чаще ориентируются на цифровые методы повышения технологической дисциплины и эффективности производства [2, 3]. Важным технологическим этапом процесса является перевозка руды карьерным автотранспортом и железнодорожными думпкарами. Слабый контроль за соблюдением технологических норм (недогруз или перегруз, смещение «шапки» погрузки и наличие негабаритных кусков) приводят к преждевременному износу техники, незапланированным простоям и росту эксплуатационных затрат, повышению рисков аварийности. Выборочные измерения и визуальный контроль операторов не обеспечивают непрерывного мониторинга и объективности данных. Автоматизация контроля соблюдения технологических норм позволяет снизить риски и повысить эффективность. Согласно данным [1], глобальный рынок цифровых технологий для горнодобывающей отрасли в 2023 году превысил 9 млрд долларов, а прогнозируемый совокупный среднегодовой темп роста до 2030 года составляет около 28 %.

Ключевыми лидерами по внедрению инноваций являются транснациональные и российские компании: Anglo American, BHP, China Coal, China Shenhua, Coal India, Codelco, ERG, Glencore, MCC, Polymetal, Rio Tinto, Vale, Алроса, ЕВРАЗ, ММК, НЛМК, Норникель, Полус, СУЭК.

Актуальные тренды продолжающейся цифровизации ГОКов накладываются на потребность в импортозамещающих технологий в условиях курса на создание российских программных продуктов.

В настоящей статье описана разработанная «Автоматизированная система контроля загрузки грузового транспорта для горно-обогатительных комбинатов с использованием технологий компьютерного зрения, в том числе лидарных технологий».

Научная новизна решений, представленных в данном проекте, состоит в совместном применении камер машинного зрения и лидаров. Для этой цели были разработаны алгоритмы сопряжения и анализа разнородных данных с камер и лидаров. При создании данных алгоритмов использовались глубокие нейронные сети и синтетические данные для их тренировки. Особенности применения синтетических данных для улучшения качества многослойных нейронных сетей при тренировке на малых выборках естественных изображений и математические механизмы повышения точности таких описаны в [4, 5].

Описание программного обеспечения

Краткое описание программного обеспечения. Продукт представляет собой систему интеллектуального анализа и контроля технологического процесса погрузки руды на горно-обогатительных предприятиях. Функционал системы:

- детектирование в кадре объекта грузового транспорта и его распознавание (самосвал / думпкары);
- распознавание RFID-меток;
- классификация элементов вагона/кузова (борта, дно, насыпной груз);
- расчет объема насыпного груза;
- расчет веса насыпного груза;
- расчет параметров загрузки;
- регистрация параметров загрузки в информационной системе предприятия;
- сравнение с нормативными параметрами, определение отклонений;
- поиск негабаритных кусков в кузове/вагоне;
- формирование аналитической отчетности.

Функциональные характеристики программного обеспечения. Система состоит из следующих компонентов.

- подсистема сегментации;
- подсистема распознавания RFID меток;
- подсистема расчета объема и веса;
- подсистема расчета паспортных параметров;
- подсистема поиска негабаритов;
- подсистема отчетности;
- веб-клиент.

Функциональные характеристики подсистемы сегментации.

- определение в кадре объекта (прием на вход изображения с видеокамер, распознавание самосвала /дмпкара);
- классификация объектов (борта кузова (вагона), дно, насыпь).

Функциональные характеристики подсистемы распознавания номеров RFID меток.

- идентификация объектов посредством RFID меток.

Функциональные характеристики подсистемы расчета объема и веса.

- расчет объема пустого кузова самосвала (дмпкара) на основании карты высот и / или на основе паспортных характеристик объема пустого кузова самосвала (дмпкара) – в кубических метрах;
- расчет объема груза в кубических метрах;
- расчет теоретического веса груза (в тоннах) на основании данных об объеме груженого самосвала (дмпкара) и насыпной плотности груза (справочная постоянная величина);
- отображение информации по самосвалу (дмпкару): дата и время события в формате YY-mm-dd hh:mm:ss; номер самосвала (дмпкара); объем груженого самосвала (дмпкара); фотофакт.

Функциональные характеристики подсистемы расчета паспортных параметров и отклонений. Расчет паспортных параметров самосвалов (дмпкаров):

- смещение шапки погрузки по длине, в мм;
- смещение шапки погрузки по ширине, в мм;
- высота шапки, в м;
- отступ от задней кромки кузова, в мм;
- объем загрузки, м³

Определение отклонений от паспортных параметров самосвала (дмпкара):

1. Сравнение фактических параметров загрузки с нормативными паспортными параметрами.

2. Для каждого рейса подсистема формирует событие, которое содержит следующую информацию:

- дата и время события в формате UTC +3, YY-mm-dd hh:mm:ss;
- номер самосвала (дмпкара);
- фактические значения паспортных параметров;
- фотофакт

3. В случае, если фактические значения паспортных параметров не соответствуют нормативным параметрам, события по таким рейсам должны содержать описание причин / причины несоответствия.

При обнаружении нарушения паспортных параметров подсистема должна выдавать уведомление.

Функциональные характеристики подсистемы поиска негабаритов.

1. Подсистема осуществляет поиск негабаритных кусков в кузове самосвала (дмпкара).

2. При обнаружении негабарита подсистема должна выдавать предупреждения.

3. Подсистема должна выдавать общее число найденных негабаритов.

4. Подсистема должна выдавать размер по каждому найденному негабариту.

5. Подсистема должна фиксировать события о найденных негабаритах. События должны содержать следующую информацию: дата и время события в формате YY-mm-dd hh:mm:ss; номер самосвала; количество негабаритов; параметры негабаритов.

Функциональные характеристики подсистемы отчетности.

– выгрузка отчета в зависимости от установленных фильтров: тип транспорта (дмпкары/самосвалы); тип нарушения; соответствие паспорту.

Апробация

За период с 2019 по 2025 год группой компаний red_mad_robot, в которую входит ООО «РЕСЕРЧ ДАТА ЛАБ», было реализовано несколько внедрений технологических решений на основе компьютерного зрения, в том числе ERG (Соколовско-Сарбайский ГОК (ССГПО, Казахстан), НЛМК, Стойленский ГОК (Белгородская обл.), Норникель, рудник «Таймырский» (Норильск).

Заключение

В работе описана автоматизированная система контроля загрузки грузового транспорта для горно-обогатительных комбинатов с использованием технологий компьютерного зрения, в том числе лидарных технологий. Основными техническими преимуществами системы являются ее широкий функционал и модульная архитектура, позволяющая выбрать необходимую комплектацию под нужды каждого заказчика. За счет связанности данных между модулями, находящимися в одной технологической сети предприятия, повышается эффективность всего участка транспортировки в целом.

Данное решение является импортозамещающим аналогом программного обеспечения в сфере цифровизации горно-обогатительных комбинатов и металлургии. Аналог VisioTruck, ПО для визуального контроля содержимого кузова грузовика на предмет негабаритных частиц. Разработчик — компания Metso:Outotec (Финляндия) — с 03.03.2022 заявила о приостановке работы в России. Смежный продукт Smart Mining, ПО для контроля работы мельниц и ленточного конвейера, разработчик — компания Siemens (Германия) — 12.05.2022 заявила о «прекращении своей производственной деятельности и всей деловой активности» в России.

Система разработана российской компанией RDL by red_mad_robot (ООО «РЕСЕРЧ ДАТА ЛАБ») при поддержке федерального проекта «Искусственный интеллект» (договор №

56ГКЦЭИИС13-D7/81950 от 21.12.2022) и зарегистрирована в Едином реестре российского ПО. Реестровая запись №19214 от 23.09.2023. Класс 12.04 «Программное обеспечение для решения отраслевых задач в области добычи полезных ископаемых».

Библиография

1. Изюмцев А. А., Клебанов Д. А. Открытое ПО — залог повышения эффективности цифровой трансформации горной промышленности // Рациональное освоение недр. — 2022. — № 5. — С. 68–71.
2. Матерова Е. С., Аксенова Ж. А., Шарафуллина Р. Р. и др. Цифровизация деятельности российских компаний горнодобывающей отрасли. — Уголь, 2024, № 11. — 117 с.
3. Сарычев А. Е., Семенихин Д. Е. Инновационные тренды развития мировой горнодобывающей отрасли: цифровизация управленческих и операционных процессов // Экономика, предпринимательство и право, 2023, т. 13, № 8, с. 2897–2908.
4. Чайников Ю. С., Судаков В. А. Об оценках интегрального риска предиктора липшицевых функций в моделях машинного обучения // Препринты ИПМ им. М. В. Келдыша, 2024. № 53. — 12 с.
5. Чайников Ю. С., Судаков В. А., Степанов М. С. Применение синтетических данных для улучшения качества многослойных нейронных сетей при тренировке на малых выборках естественных изображений // Материалы XXIII Междунар. конф. «Вычислительная механика и современные прикладные программные системы (ВМСППС'2023)». — М.: МАИ, 2023. — С. 147–148.

AUTOMATED LOAD-MONITORING SYSTEM FOR CARGO TRANSPORT AT MINING AND PROCESSING PLANTS USING COMPUTER VISION TECHNOLOGIES, INCLUDING LIDAR

Yuri S. Chainikov

Moscow Aviation Institute, Moscow, Russia

gutorin@gmail.com

Abstract. This paper describes the functionality and implementation results of a domestic software platform—registered in the Unified Register of Russian Software (registration entry No. 1807028)—designed for intelligent analysis and

adaptive control of industrial processes. A key component of the system is a module that detects cargo-transport objects in video frames, recognizes them, and classifies elements such as truck/railcar sidewalls, bed, and bulk material using deep neural networks.

Keywords. Industrial artificial intelligence, transport-loading control, over-sized-object detection, LiDAR technologies, neural networks.

* * *

УДК 004.032:57.087.1

doi:10.18720/SPBPU/2/id25-536

РАСПОЗНАВАНИЕ ДВИЖЕНИЙ КОБОТОВ ПРИ ВЫПОЛНЕНИИ ТЕХНОЛОГИЧЕСКИХ ОПЕРАЦИЙ

Ассалама Лара¹, Потехин Вячеслав Витальевич²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹assalama.l@edu.spbstu.ru, ²Slava.Potekhin@spbstu.ru

Аннотация. Системы управления на основе сигналов sEMG доказали свою эффективность и удобство в использовании. В отличие от большинства подходов, в работе используются исходные значения сигналов в качестве признаков и применяется усреднение для увеличения выборки. Разработана многослойная CNN-модель для классификации 53 движений (NinaPro-DB5). Модели 2L-CNN и 3L-CNN достигли точности 98,1 % и 97,8 %, соответственно, подтвердив справедливость применения метода.

Ключевые слова. Распознавание движений; модели глубокого обучения; сверточная нейронная сеть (CNN); коллаборативный робот.

Введение

Помимо своего широкого применения в различных отраслях промышленности, роботизированные манипуляторы стали жизненно необходимыми для выполнения производственных задач. Более того, благодаря значительным достижениям в области сенсоров и систем управления, современные коботы превратились из пассивной замены в активный элемент повседневной жизни поль-

зователя, помогая ему комфортно и эффективно справляться с повседневными задачами.

Сверточные нейронные сети (CNN) стали одним из наиболее популярных методов, применяемых в данной области для решения разнообразных задач, таких как распознавание жестов и движений [1,2], выявление мышечной усталости [3], реабилитация [4], классификация двигательных единиц [5], взаимодействие человек–компьютер (HCI) [6] и оценки нагрузки [7].

В последние годы всё больше подходов используют сигналы поверхностной электромиографии (пЭМГ) для распознавания жестов рук. Ряд исследований продемонстрировал обнадеживающие результаты, применимые в реальных условиях [8-10]. Всё это стало основанием для выбора в представленной работе подхода на основе распознавания жестов рук с использованием сигналов пЭМГ и CNN.

Сверточная нейронная сеть (CNN) это тип алгоритмов глубокого обучения. Она включает сверточный слой, который применяет к входным данным набор ядер (фильтров). Данная операция может быть представлена следующей формулой:

$$S(i, j) = (I * K)(i, j) = \sum_n \sum_m (I(i + m, j + n) \cdot K(m, n)),$$

где S — это выходная карта признаков, I — входные данные, K — ядро (фильтр).

Набор данных NinaPro-DB5 содержит образцы сигналов пЭМГ, собранные с использованием двух браслетов Муо, каждый из которых оснащён восемью датчиками. Данные представляют 52 жеста руки и положение покоя, то есть всего охватывают 53 различных класса. Наиболее полное описание набора данных NinaPro-DB5 представлено в работе [11].

Применяемый подход

Предложено два варианта классификации данных с разделением на 53 класса, определённых в наборе данных: двухслойную сверточную нейросеть (2L-CNN) и трёхслойную (3L-CNN), а также проведено сравнение результатов для последующего анализа влия-

ния глубины нейросети на производительность модели. В качестве критериев оценки были выбраны: точность, потери модели, время обучения и время тестирования. Точность и потери характеризуют способность модели к корректной классификации, время обучения имеет значение на этапе подготовки модели, а время тестирования критично при её использовании в реальном времени, например, в системе управления протезом или коботом.

Дополнительные признаки не извлекались, поскольку в работе использовались исходные значения сигналов в качестве признаков, что позволило уменьшить сложность реализованной системы. Кроме того, применялись данные только с одного браслета Муо (8 датчиков), что делает систему более удобной для конечного пользователя, поскольку исключает необходимость ношения двух устройств одновременно. Длину сигнала определили методом, описанным в предыдущей работе [12].

Обучая модели на оригинальном наборе данных выяснили, что имеющегося количества образцов недостаточно для достижения желаемых результатов. Поэтому было принято решение удвоить количество данных, усреднив каждые две последовательные выборки в каждом классе и добавив их к исходному классу. Это позволило улучшить результаты, но они всё ещё не соответствовали целевым показателям. Тогда, усреднив все возможные пары выборок в каждом классе и добавив полученные значения к исходному классу, были сгенерированы новые данные по выражению: $C_n = n(n - 1)/2$, где n – количество исходных выборок в классе. Так получили многократно увеличенный набор данных.

На рис. 1 показана структура модели 2L-CNN, которая состоит из четырёх блоков: входного слоя с 8 каналами, сверточных блоков (слой свёртки и слой подвыборки), выравнивающего слоя (flat) и выходного слоя с 53 нейронами. Для построения модели 3L-CNN добавили ещё один сверточный блок.

Предлагаемый подход включает следующие этапы:

1. Выбор длины сигнала и предварительная обработка сигналов, имеющих данную или большую длину, с приведением их к выбранной длине.




Рис. 1. Структура модели 2L-CNN

2. Увеличение набора данных, состоящего из предварительно обработанных образцов.
3. Проектирование модели и ее обучение с использованием нового набора данных.
4. Тестирование модели.

Для данной работы подготовлен набор данных NP-DB5 и необходимые библиотеки на Python. Для обучения и обработки использовались пакеты TensorFlow и другие инструменты Python.

Полученные результаты

Эффект увеличения выборки. Модель не смогла обучиться на исходном наборе данных из-за недостаточного количества образцов. Для увеличения выборки использовали арифметическое усреднение, что позволило удвоить размер данных и повысить точность до 54,3 % (2L-CNN) и 55 % (3L-CNN) соответственно при длине

сигнала в 200 образцов. Однако этих результатов оказалось недостаточно, так как увеличение выборки с усреднением пары образцов в каждом классе не дало необходимых эффект. В результате получилось три набора: 102 063 образца длиной 200 и 400 образцов и 67 006 образцов длиной 650. В итоге увеличение размера данных улучшило обучение модели.

Двухслойная сверточная нейронная сеть (2L-CNN). Как показано на рис. 2, точность модели составляет минимум 94,5 % на наборе данных с длиной сигнала 400 временных отсчётов и максимум 98,1 % на наборе с длиной сигнала 650 временных отсчётов. Кроме того, значения потерь также остаются низкими: при длине сигнала 650 модель показала значение потерь менее 0,1, а наибольшее значение потерь при длине сигнала 400 не превысило 0,22.

Трёхслойная сверточная нейронная сеть (3L-CNN). На рис. 3 представлены результаты обучения модели на трёх наборах данных. Как видно, чем длиннее сигналы, тем выше точность. Потери были низкими для наборов с длиной сигнала 650 и 400 временных отсчётов — 0,11 и 0,1 соответственно, тогда как для набора с длиной 200 временных отсчётов потери были немного выше —




Рис. 2. Точность и потери модели 2L-CNN




Рис. 3. Точность и потери модели 3L-CNN

0,27. Это свидетельствует о том, что увеличение количества признаков (временных отсчётов сигнала) способствует лучшему обучению модели при наличии достаточного количества обучающих данных.

Сравнение производительности моделей 2L-CNN и 3L-CNN представлено в таблице 1. Модель 2L-CNN показала чуть более высокую точность (98,1 % против 97,8 %) и меньшие потери (0,076 против 0,11) по сравнению с 3L-CNN. Кроме того, 2L-CNN обучалась почти в два раза быстрее (4997 с против 10075 с) и демонстрировала более короткое время тестирования (1,49 мс против 3,101 мс). Таким образом, 2L-CNN превосходит 3L-CNN по всем ключевым критериям производительности.

Таблица 1

Производительность моделей 2L-CNN и 3L-CNN

Модель	Критерии			
	Точность, %	Потери	Время обучения, с	Время тестирования, мс
2L-CNN	98,1	0,076	4997	1,49
3L-CNN	97,8	0,11	10075	3,101

Таблица 2

Сравнение предложенных подходов с существующими

Модель	Набор данных	Класс	Точность, %
CNN[13]	NinaPro-DB5	52	74,51
IMC-CNN[10]	NinaPro-DB5	10	97,5
ID-CNN-RNN[14]	Theirs	20	91 real-time 98,96 training
NN[15]	NinaPro-DB5	9	73.04
2L-CNN	NinaPro-DB5	53	98.1
3L-CNN	NinaPro-DB5	53	97.8

Несмотря на то, что наши модели должны были классифицировать все 53 класса из набора данных NinaPro-DB5, что значительно усложняет задачу, они всё же превзошли другие подходы, использующие тот же или аналогичные наборы данных с таким же или меньшим числом классов, как показано в табл. 2. Кроме того, большинство существующих решений используют более сложные гибридные модели, сочетающие CNN с другими методами глубокого обучения, в то время как наши модели были проще, так как основаны исключительно на CNN без дополнительных алгоритмов. Более того, наш подход ещё проще благодаря отказу от этапа выделения признаков: мы работали напрямую с исходными значениями сигналов, что позволило сократить время обработки и снизить вычислительную нагрузку.

Заключение

В данной работе представлены две модели сверточных нейронных сетей (CNN) и классификация набора движений. Предполагается, что увеличение выборки с помощью усреднения помогает компенсировать его малый объём, что и позволяет достичь высокой производительности модели. Изучено влияние длины сигнала и установлено: более длинный сигнал обеспечивает наилучшие

результаты, что является ожидаемым, поскольку сигнал содержит больше признаков.

Двух слоёв CNN оказалось достаточно для достижения желаемой точности. Добавление третьего слоя не улучшило показатели точности и потерь, но значительно увеличило время обучения и тестирования. Продолжительное тестирование может негативно повлиять на работу системы управления движением при использовании данной модели. Поэтому рекомендовано использовать 2L-CNN с длиной сигнала 200 или 650 временных отсчётов. Однако 3L-CNN также может применяться при длине сигнала 400 временных отсчётов, особенно если время обучения и тестирования не критично, как, например, в экспериментальных приложениях.

Разработанный подход, основанный на использовании исходных значений сигналов пЭМГ в качестве признаков и увеличении выборки посредством усреднения, а также построении многослойных моделей CNN, позволил достичь наилучших результатов по сравнению с рядом других подходов. Модели достигли точности 98,1 % (2L-CNN) и 97,5 % (3L-CNN). Такие классификаторы благодаря высокой точности и низкой сложности способны существенно повысить эффективность систем управления движением.

Библиография

1. Lan, S., He, Z., Chen, W. & Chen, L. (2018). Hand Gesture Recognition Using Convolutional Neural Networks. 2018 USNC-URSI Radio Science Meeting (Joint with AP-S Symposium), USNC-URSI 2018 – Proceedings, 147–148. <https://doi.org/10.1109/USNC-URSI.2018.8602809>.
2. Kishore, T., Remabai, S. S., Retnaswamy, C. & Paul, E. S. (2025). Enhanced EMG-based Gesture Recognition using Hybrid CNN-BiLSTM Architecture with Channel Attention. Biomedical and Pharmacology Journal, 18(December Spl Edition), 315–329. <https://doi.org/10.13005/BPJ/3090>.
3. Wu, W. T., Ruan, S. J., Tu, Y. W., Huang, Y. L. & Guo, H. J. (2025). A Hybrid Model for Muscle Fatigue Detection: Integrating Time and Frequency Domain Features of sEMG Signals with RPE Scale During Isometric Contraction. IEEE Transactions on Instrumentation and Measurement. <https://doi.org/10.1109/TIM.2025.3548790>.

4. **Radhakrishnan, M., Premkumar, V. J., Prahaladhan, V. B., Mukesh, B. & Nithish, P.** (2024). Convolution neural network based multi-class classification of rehabilitation exercises for diastasis recti abdominis using wearable EMG-IMU sensors. *Engineering Computations* (Swansea, Wales). <https://doi.org/10.1108/EC-02-2024-0114>.
5. **Li, Y., Zheng, Y., Xu, G., Zhang, S., Liang, R. & Ji, R.** (2024). Classification of Action Potentials With High Variability Using Convolutional Neural Network for Motor Unit Tracking. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 32, 905–914. <https://doi.org/10.1109/TNSRE.2024.3364716>.
6. **Li, Q. & Langari, R.** (2022). EMG-based HCI Using CNN-LSTM Neural Network for Dynamic Hand Gestures Recognition. *IFAC-PapersOnLine*, 55(37), 426–431. <https://doi.org/10.1016/J.IFACOL.2022.11.220>.
7. **Wahid, A., Ullah, K., Ullah, S. I., Amin, M., Almutairi, S. & Abohashrh, M.** (2024). sEMG-based Upper Limb Elbow Force Estimation Using CNN, CNN-LSTM, and CNN-GRU Models. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2024.3451209>
8. **Ge, Z., Liu, W., Wu, Z., Cai, M. & Zhao, P.** (2022). GESTURE RECOGNITION AND MASTER-SLAVE CONTROL OF A MANIPULATOR BASED ON SEMG AND CNN-GRU. *ASME International Mechanical Engineering Congress and Exposition, Proceedings (IMECE)*, 4. <https://doi.org/10.1115/IMECE2022-94788>.
9. **Abdelaziz, M. H., Mohamed, W. A. & Selmy, A. S.** (2024). Hand Gesture Recognition Based on Electromyography Signals and Deep Learning Techniques. *Journal of Advances in Information Technology*, 15(2), 255–263. <https://doi.org/10.12720/JAIT.15.2.255-263>.
10. **Li, J., Wei, L., Wen, Y., Liu, X. & Wang, H.** (2022). Hand gesture recognition based improved multi-channels CNN architecture using EMG sensors. *Journal of Intelligent and Fuzzy Systems*, 43(1), 643–656. <https://doi.org/10.3233/JIFS-212390>
11. **Pizzolato, S., Tagliapietra, L., Cognolato, M., Reggiani, M., Müller, H. & Atzori, M.** (2017). Comparison of six electromyography acquisition setups on hand movement classification tasks. *PloS One*, 12(10). <https://doi.org/10.1371/JOURNAL.PONE.0186132>.
12. **Vyacheslav V. Potekhin, Lara Assalama.** (2022). HAND GESTURE RECOGNITION USING SEMG WITH XGBOOST, AND AVERGING FOR AUGMENTATION. Санкт Петербург: ПОЛИТЕХ ПРЕСС– Санкт-Петербургский политехнический университет Петра Великого, 2022. Vol. 2, pp. 74-88. 501;57.085.1.
13. **Shen, S., Gu, K., Chen, X. R., Lv, C. X. & Wang, R. C.** (2020). Gesture Recognition Through sEMG with Wearable Device Based on Deep Learning.

Mobile Networks and Applications, 25(6), 2447–2458. <https://doi.org/10.1007/S11036-020-01590-8/METRICS>.

14. **Li, S., Zhang, Y., Tang, Y., Li, W., Sun, W. & Yu, H.** (2023). Real-Time sEMG Pattern Recognition of Multiple-Mode Movements for Artificial Limbs Based on CNN-RNN Algorithm. *Electronics* 2023, Vol. 12, Page 2444, 12(11), 2444. <https://doi.org/10.3390/ELECTRONICS12112444>.

15. **Mora, M. C., García-Ortiz, J. v. & Cerdá-Boluda, J.** (2024). sEMG-Based Robust Recognition of Grasping Postures with a Machine Learning Approach for Low-Cost Hand Control. *Sensors* (Basel, Switzerland), 24(7). <https://doi.org/10.3390/S24072063>.

MOTION RECOGNITION OF COBOT'S OPERATIONS USING CNN

Lara Assalama¹, Vyacheslav V. Potekhin²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹assalama.l@edu.spbstu.ru, ²Slava.Potekhin@spbstu.ru

Abstract. sEMG-based control systems have proven to be effective and easy to use. Unlike most approaches, our work uses the original signal values as features and applies averaging to augment the dataset. We developed multi-layer CNN models to classify 53 movements (NinaPro-DB5). The 2L-CNN and 3L-CNN models achieved an accuracy of 98.1% and 97.8%, confirming the potential of this method for improving the efficiency and usability of prosthesis control systems.

Keywords. Motion recognition; deep learning models; convolutional neural network (CNN); collaborative robot.

* * *

«ПРЕДИКТИВНАЯ АНАЛИТИКА И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ»

УДК 004.89, 921.791
doi:10.18720/SPBPU/2/id25-537

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ КОНТРОЛЯ КАЧЕСТВА КОНТАКТНОЙ ТОЧЕЧНОЙ СВАРКИ

Болотов Сергей Владимирович¹, Крутолевич Сергей Константинович²

Белорусско-Российский университет, г. Могилёв, Республика Беларусь

¹s.v.bolotov@mail.ru, ²s_krutolevich@tut.by

Аннотация. Проведен анализ интеллектуальных систем контроля качества контактной точечной сварки. Предложено использовать рекуррентную нейронную сеть со слоем скрытых нейронов для создания математической модели зависимости критериев качества контактной сварки (диаметра литого ядра и усилия на разрыв сварной точки) от параметров её режима (усилия сжатия электродов и энергии, выделяемой в межэлектродной зоне, которая рассчитывается на основе сварочного тока и напряжения между электродами в каждый полупериод сетевого напряжения) и геометрических размеров и материалов свариваемых деталей и электродов. Для обучения фреймворка Keras использовались NumPy-массивы, содержащие набор исходных данных для образцов из низкоуглеродистой стали 08кп, среднеуглеродистой стали 40Х и коррозионно-стойкой стали 12Х18Н10Т для толщин от 0,5 до 3 мм. Точность предсказаний модели по диаметру литого ядра составила 89%, а по разрушающему усилию 84%.

Ключевые слова. Контактная точечная сварка, диаметр ядра, усилие на разрыв, нейронные сети.

Введение

Контактная точечная сварка, осуществляемая за счёт расплавления свариваемых деталей под действием нагрева от протекания сварочного тока $I_{св}$ между двумя предварительно сжатыми усилием ФСЖ цилиндрическими электродами (рис. 1), находит широкое применение в машиностроении. Огромное влияние при этом уделяется вопросам повышения качества контактной сварки [1].

Технология контактной точечной сварки определяется материалом и толщинами свариваемых деталей [2]. К основным параметрам режима контактной сварки относят:

- силу сварочного тока $I_{св}$.
- длительность протекания сварочного тока $\tau_{св}$;
- усилие сжатия для свариваемых деталей ФСЖ.

В качестве критериев качества контактной сварки [1] используют:

- усилие на разрыв ФРАЗР;
- диаметр литого ядра сварной точки $D_{Я}$.

Системы, основанные на искусственном интеллекте, находят всё большее применение для построения систем контроля и управления сварочными процессами [3-6]. Разрабатываются интеллектуальные системы неразрушающего контроля, позволяющие прогнозировать качество сварки на основе анализа динамики изменения параметров сварки. В работе [7] на основе измерения тока сварки, напряжения на электродах и усилия сжатия с помощью Байесовской сети доверия осуществляется отнесение диаметра




Рис. 1. Схема процесса контактной точечной сварки: 1 – свариваемые детали, 2 – электроды, 3 – литое ядро, 4 – сварочный трансформатор

сварного ядра к одному из нескольких диапазонов. Прогнозирование диаметра литого ядра на основе нейронной сети прямого распространения может быть осуществлена на основе измерения сварочного тока и напряжения на электродах в каждом полупериоде сетевого напряжения [4]. С помощью конкурентной нейронной сети LVQ при регистрации изменения усилия сжатия электродов за счёт теплового расширения металла при сварке можно отнести сварное соединение к одному из пяти типов: “insufficientwelding”, “poorwelding”, “goodwelding”, “richwelding”, “excessivewelding” [8].

К недостаткам имеющихся интеллектуальных систем контроля качества контактной точечной сварки, сдерживающим их применение в промышленности, относятся: необходимость проведения многочисленных предварительных экспериментов по сварке и измерению размеров литой зоны соединения или разрушающего усилия для каждого типоразмера и материала сварных соединений, для каждой единицы сварочного оборудования.

В работе [9] установлено, что энергия $Q_{\text{эз}}$, выделяемая в межэлектродной зоне определяет размеры литой зоны и требуемое разрушающее усилие сварного соединения. Установлено, что изменение усилия сжатия электродов $F_{\text{сж}}$, требует корректировки вводимой энергии для получения заданного диаметра литого ядра $D_{\text{я}}$ [10].

Авторами статьи предлагается использование нейронной сети для создания математической модели зависимости критериев качества контактной сварки от параметров её режима, геометрических размеров и материалов свариваемых деталей и электродов:

$$F_{\text{РАЗР}} = f(Q_{\text{эз}}(t), F_{\text{сж}}(t), W_l). \quad (1)$$

$$D_{\text{я}} = f(Q_{\text{эз}}(t), F_{\text{сж}}(t), W_l), \quad (2)$$

где $Q_{\text{эз}}(t)$ — изменение энергии, выделяемой между электродами в процессе сварки; $F_{\text{сж}}(t)$ — изменение усилия сжатия электродов в процессе сварки; W_l — множество параметров размеров и материалов свариваемых деталей и электродов, желаемого

диаметра литого ядра и усилия на разрыв с допустимыми отклонениями.

Нейронная сеть для контроля качества сварки

Предложен метод контроля сварочного процесса с использованием нейронной сети на основе фреймворка глубокого обучения Keras версии 2.2.5. Выбор данного фреймворка обусловлен:

- возможностью быстро изменять топологию нейронной сети, добавляя и удаляя скрытые слои;
- поддержкой как сверточных так и рекуррентных нейронных сетей.

Для реализации алгоритма была создана рекуррентная нейронная сеть со слоем скрытых нейронов. Топология нейронной сети представлена на рис. 2.

В табл. 1 представлены входные параметры нейронной сети




Рис. 2. Топология рекуррентной нейронной сети

Таблица 1

Входные параметры

№ п/п	Входной параметр
1	δ_1, δ_2 – толщины свариваемых деталей
2	$d_э$ – диаметр контакта «электрод–деталь»
3	ТПЛ – температура плавления материала свариваемых деталей
4	$\rho_M, \rho_э$ – удельные электрические сопротивления материала свариваемых деталей и электродов при температуре 20 °С
5	$\gamma_M, \gamma_э$ – плотность материала свариваемых деталей и электродов
6	$C_M, C_э$ – теплоемкость материала свариваемых деталей и электродов
7	D_R – желаемый диаметр литого ядра
8	β_D – допустимое отклонение желаемого диаметра ядра D_R от реального $D_я$
9	F_R – желаемое усилие на разрыв
10	β_F – допустимое отклонение желаемого усилия на отрыв F_R от реального $F_{РАЗР}$
11	$F_{СЖ}$ – усилие сжатия электродов
12	$Q_{ээ}$ – энергия, выделяемая между электродами

Входные параметры 1–10 задаются до начала процесса сварки из имеющейся базы данных. Входные параметры $F_{СЖ}$ и $Q_{ээ}$ определяются в процессе сварки в каждый полупериод сетевого напряжения.

Сигналы с датчика сварочного тока на основе пояса Роговского $I_{СВ}$ и датчика напряжения между электродами $U_{ээ}$ с частотой 20 кГц поступают на вход устройства сбора данных NI USB-6251 (рис. 3). Предварительно производится аппаратное интегрирование выходного напряжения с пояса Роговского для выделения сигнала тока.




Рис. 3. Графики изменения сварочного тока $I_{СВ}$, напряжения между электродами $U_{ээ}$ и энергии $Q_{ээ}$ в процессе сварки

Энергия $Q_{\text{ЭЭ}}$ вычисляется в течение каждого полупериода сетевого напряжения (см. рис. 3):

$$Q_{\text{ЭЭ}} = \sqrt{\sum_{k=1}^m U_{\text{ЭЭ}}^2} \cdot \sqrt{\sum_{k=1}^m I_{\text{св}}^2}, \quad (3)$$

где m — количество отсчётов (выборок) в течение одного полупериода напряжения сети.

Усилие сжатия электродов РСЖ с помощью тензомоста с усилителем фиксируется с частотой 1 кГц и усредняется в течение каждого полупериода сетевого напряжения.

В качестве активационных функций искусственного нейрона применялась сигмоидальная функция.

Для обучения фреймворка Keras использовались Numpy-массивы, содержащие набор исходных данных. Подготовлены наборы данных для образцов из низкоуглеродистой стали 08кп, среднеуглеродистой стали 40Х и коррозионно-стойкой стали 12Х18Н10Т. Толщина пластин изменялась в диапазоне от 0,5 до 3 мм. Сварку производили на машине контактной точечной сварки МТ-3201.

В процессе обучения был определен диапазон изменения энергии, вводимой в межэлектродную зону

$$Q_{\text{ЭЭ}}^{\min} < Q_{\text{ЭЭ}} < Q_{\text{ЭЭ}}^{\max},$$

при котором диаметр ядра свариваемой точки $D_{\text{я}}$ отклоняется от желаемого значения $D_{\text{р}}$ не более чем на значение β_D .

$$\frac{|D_{\text{р}} - D_{\text{я}}|}{D_{\text{р}}} < \beta_D,$$

а диапазон изменения разрушающего усилия $F_{\text{РАЗР}}$ отклоняется от желаемого значения $F_{\text{р}}$ не более чем на значение β_F .

$$\frac{|F_{\text{р}} - F_{\text{РАЗР}}|}{F_{\text{р}}} < \beta_F.$$

Точность предсказаний по диаметру литого ядра составила 89 %, а по разрушающему усилию — 84 %.

Заключение

Анализ имеющихся интеллектуальных систем контроля качества контактной точечной сварки показал, что одним из их недостатков является отсутствие учёта размеров и материала свариваемых деталей и электродов.

Предложен метод контроля сварочного процесса с использованием нейронной сети, позволяющий изменять её топологию, добавляя и удаляя скрытые слои, поддерживать как сверточные так и рекуррентные нейронные сети.

Создана математическая модель зависимости критериев качества контактной сварки от параметров её режима (усилия сжатия электродов $F_{\text{сж}}$ и энергии $Q_{\text{ЭЭ}}$, вводимой в межэлектродную зону на каждом полупериоде сетевого напряжения), геометрических размеров и материалов свариваемых деталей и электродов, желаемого диаметра литого ядра и усилия на разрыв с допустимыми отклонениями

Для обучения фреймворка Keras использовались Numpy-массивы, содержащие набор исходных данных для образцов из низкоуглеродистой стали 08кп, среднеуглеродистой стали 40Х и коррозионно-стойкой стали 12Х18Н10Т с толщиной пластин от 0,5 до 3 мм.

В процессе обучения был определен диапазон изменения энергии, вводимой в межэлектродную зону, при котором диаметр ядра свариваемой точки $D_{\text{я}}$ и диапазон изменения разрушающего усилия $F_{\text{РАЗР}}$ отклоняются от желаемых значений с заданным допуском. Точность предсказаний по диаметру литого ядра составила 89%, а по разрушающему усилию 84%.

Разработанная математическая модель может использоваться для контроля качества контактной точечной сварки ответственных конструкций в машиностроении.

Библиография

1. Климов, А. С. Контактная сварка. Вопросы управления и повышения стабильности качества / А. С. Климов. — Москва: ФИЗМАТЛИТ, 2011. — 216 с.

2. **Березиенко, В. П.** Технология сварки давлением / В. П. Березиенко, С. Ф. Мельников, С. М. Фурманов. — Могилев: Белорусско–Российский университет, 2009. — 256 с.

3. **Sampaio D. J. B. S., Link N., Moscato L. A.** Quality estimation using generic model parameters and neural network // ABCM Symposium Series in Mechatronics. 2006. Vol. 2. P. 765–771.

4. **Патон, Б. Е.** Оценка качества контактной точечной сварки с помощью нейронных сетей / Б.Е. Патон, Н.В. Подола, В.С. Гавриш // Автоматическая сварка. — 1998. — № 12. — С. 3–10.

5. Analysis and development of real-time control methodology in resistance spot welding / C.L. Tsai [et al.] // Welding Journal. 1991. № 6. P. 339–351.

6. **Zhang H., Zhao Z., Yang, J.** Control of contact welding process based on adaptive robust control and fuzzy neural network // IEEE Transactions on Industrial Electronics. 2022. № 7. P. 515–524.

7. Studying the Quality of Resistance Spot Welding Joints Using Bayesian Networks / P. Laurinen [et al.] // AIA 2004: The IASTED International Conference on Artificial Intelligence and Applications (February 16–18, 2004). Innsbruck (Austria), 2004. P. 705–711.

8. **Park Y. J., Cho H.** Quality evaluation by classification of electrode force patterns in the resistance spot welding process using neural networks // Proceedings of the Institution of Mechanical Engineers. Part B: Journal of Engineering Manufacture. 2004. Vol. 218, № 11. P. 1513–1524.

9. **Болотов, С. В.** Энергоэффективная технология контактной рельефной сварки Т-образных сварных соединений / С. В. Болотов, Д. Н. Юманов, С. М. Фурманов // Вестник Белорусско-Российского университета. — 2025. — № 1. — С. 5–13.

10. **Поляков, А. Ю.** Влияние усилия сжатия электродов на величину вводимой энергии при контактной рельефной сварке с расплавлением / А. Ю. Поляков, А. О. Коротеев, С. В. Болотов // Сварочное производство. — 2022. — № 1. — С. 16–22.

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR QUALITY CONTROL OF CONTACT SPOT WELDING

Sergey S. Bolotov¹, Sergey K. Krutolevich²

Belarusian-Russian University, Mogilev, Republic of Belarus

¹s.v.bolotov@mail.ru, ²s_krutolevich@tut.by

Abstract. The analysis of intelligent quality control systems for contact spot welding is carried out. It is proposed to use a recurrent neural network with a

layer of hidden neurons to create a mathematical model of the dependence of the quality criteria of contact welding (the diameter of the cast core and the breaking force of the weld point) on the parameters of its mode (the compression force of the electrodes and the energy released in the interelectrode zone, which is calculated based on the welding current and voltage between the electrodes in each half-cycle of the mains voltage) and the geometric dimensions and materials of the parts and electrodes to be welded. To train the Keras framework, Numpy arrays were used containing a set of source data for samples made of low-carbon steel 08kp, medium-carbon steel 40X and corrosion-resistant steel 12X18H10T for thicknesses from 0,5 to 3 mm. The accuracy of the model's predictions for the diameter of the cast core was 89 %, and for the destructive force 84 %.

Keywords. Contact spot welding, core diameter, breaking force, neural networks.

* * *

УДК 629.7.08

doi:10.18720/SPBPU/2/id25-538

ОЦЕНКА ТЕХНИЧЕСКОГО СОСТОЯНИЯ И ПРОГНОЗ ОТКАЗОВ ТЕХНИЧЕСКИХ СИСТЕМ С ИСПОЛЬЗОВАНИЕМ ВЕРОЯТНОСТНО-ГАРАНТИРУЮЩЕГО ПОДХОДА

Ким Роман Валерьевич

Московский авиационный институт

(Национальный исследовательский университет), Москва, Россия

kimrv@mai.ru

Аннотация. В статье предложен подход к оценке состояния технических систем и прогноза их отказов. В основе предложенного подхода лежат методы получения гарантированных по вероятности оценок состояния на основе параметрической информации, регистрируемой в процессе эксплуатации системы. Рассмотрены правила формирования оценок технического состояния и условия принятия решения о возможности дальнейшей эксплуатации системы. Приведен пример прогноза отказов турбовентиляторного двигателя летательного аппарата, подтверждающий эффективность предложенного подхода.

Ключевые слова. Оценка состояния, прогноз отказов, предиктивная аналитика, вероятностное оценивание, эксплуатация по состоянию.

Введение

Оценка состояния и прогноз отказов технических систем и их элементов являются одними из ключевых задач в рамках проблемы повышения эффективности и безопасности эксплуатации технических систем. Их эффективное решение является неотъемлемым условием перехода на технологии эксплуатации техники «по техническому состоянию». При этом развитие технологий сбора, накопления и обработки информации о функционировании таких систем открывает новые возможности для развития и применения методологического аппарата для их решения. Случайный характер факторов, воздействующих на систему в процессе её эксплуатации, приводит к тому, что оценки состояния системы по существу носят случайный характер. При этом отсутствие полных вероятностных описаний воздействующих факторов обуславливают целесообразность применения гарантирующих подходов к решению задачи получения таких оценок.

Постановка задачи

Общую постановку задачи сформулируем следующим образом: будем предполагать, что в процессе эксплуатации системы для измерения с некоторой частотой доступен n -мерный вектор контролируемых параметров $X(t_i)$, характеризующих состояние системы, её подсистем, агрегатов, узлов в моменты времени t_i . Совокупность измерений вектора X , полученных в периоды прошлой эксплуатации и в текущем сеансе эксплуатации, формирует выборку X^N , содержащую N измерений вектора.

Необходимо на основе выборки X^N получить оценку текущего состояния системы и принять решение о возможности её дальнейшей эксплуатации.

Также будем предполагать, что если система может функционировать в различных режимах, то существует правило, позволяющий однозначно идентифицировать режим функционирования в любой момент времени. Например, для самолётов такими

режимами могут быть: «Руление», «Разбег», «Взлёт», «Набор высоты», «Крейсерский полёт», «Снижение», «Посадка», «Пробег», для авиационного двигателя — «Номинальный режим», «Взлётный режим», «Форсаж», «Малый газ».

В зависимости от доступной дополнительно априорной информации о свойствах системы общая постановка может быть уточнена. Такая дополнительная информация также влияет на доступные методы решения задачи, некоторые из которых рассмотрены ниже.

Методика вычисления вероятностно-гарантированных оценок технического состояния

Основное предположение в рамках предлагаемых методов оценки состояния заключается в том, что штатно функционирующая техническая система обеспечивает нахождение значений контролируемых параметров внутри некоторой области — области штатного функционирования (ОШФ). По мере эксплуатации системы происходит износ её элементов, в результате которого снижается способность сохранять значения параметров такой внутри. Это может проявляться в появлении систематического сдвига значений, увеличении разброса значений, изменении корреляционных связей между параметрами.

Поскольку система подвергается воздействию случайных факторов, а также вследствие наличия ошибок измерений, факт принадлежности текущих значений контролируемых параметров ОШФ, а также способность системы охранять значения внутри такой области могут быть оценены только в вероятностном смысле. При этом помимо методов получения таких оценок важным элементом является и формирование самой ОШФ.

Вычисление вероятностно-гарантированных оценок при известных диапазонах допустимых значений контролируемых параметров. Предположим, что в качестве априорной информации о системе доступны значения границ диапазонов контролируемых параметров при штатном функционировании системы в разных режимах. В этом случае ОШФ может быть представлена в виде ги-




Рис. 1. Приведение области штатного функционирования к гиперкубу

перпараллелепипеда в пространстве контролируемых параметров. Для удобства дальнейших расчетов, а также для снижения влияния масштаба значений отдельных параметров на итоговый результат такой гиперпараллелепипед приводится к гиперкубу (рис. 1) с использованием соотношения (1)[1].

$$z_j = \frac{\left(x_j - \frac{1}{2}(x_{j\min} + x_{j\max})\right)}{\frac{1}{2}(x_{j\min} - x_{j\max})}. \quad (1)$$

Условие принадлежности текущего вектора нормированных контролируемых параметров гиперкубу, имеет вид (2)

$$\max_{j=1, \dots, n} |z_j(t_i)| < 1. \quad (2)$$

Однако (2) не в полной мере отражает длину близость точки к границе ОШФ. В дальнейшем для оценки степени принадлежности вектора контролируемых параметров ОШФ будем использовать евклидово расстояние от центра ОШФ до точки, соответствующей значениям нормированных контролируемых параметров (длину вектора контролируемых параметров в нормированном пространстве) (3).

$$\Phi(Z(t_i)) = \sqrt{\sum_{j=1}^n z_j^2(t_i)}. \quad (3)$$

В этом случае условие, отражающее степень принадлежности вектора контролируемых параметров ОШФ, может иметь вид (4), или (5).

$$\Phi(Z(t_i)) < 1. \quad (4)$$

$$\frac{1}{\sqrt{n}} \Phi(Z(t_i)) < 1. \quad (5)$$

Соотношение (4) отражает более осторожный («пессимистичный») подход к оценке состояния, поскольку в этом случае оценивается степень принадлежности многомерному шару, вписанному в гиперкуб. Соотношение (5) отражает «оптимистичный» подход, оценивая принадлежность описанному вокруг гиперкуба шару. В первом случае может возникнуть ситуация, при которой вектор нормированных контролируемых параметров принадлежит области штатного функционирования, но условие принадлежности (4) не выполняется (рис. 2а). Во втором случае наоборот условие принадлежности (5) может выполняться даже, если вектор не принадлежит гиперкубу (рис. 2б).

С учетом вышеизложенного алгоритм вычисления вероятностно-гарантированных оценок состояния системы и принятия решения о возможности её дальнейшей эксплуатации состоит из следующих шагов:




Рис. 2. «Пессимистичный» и «Оптимистичный» подход к оценке состояния

1. На основании сформированной к текущему моменту эксплуатации выборку X^N формируется выборка Z^N нормированных значений контролируемых параметров;

2. На основании выборки Z^N рассчитывается выборка Φ^N значений критериальной функции;

3. По выборке значений критериальной функции строится её выборочная функция распределения $F^N(\Phi)$;

4. Выборочная функция распределения аппроксимируется каким-либо теоретическим законом (например, распределением Вейбулла).

В результате выполнения шагов 1–4 имеем аналитическую зависимость $F(\Phi)$ – функцию распределения значений критериальной функции Φ . На основании такой аналитической зависимости для любого заданного значения $\Phi(Z(t_i))$ может быть рассчитано значение вероятности (прямой критерий) того, что значение функции Φ не превысит некоторого заданного порогового значения. И наоборот, для некоторого заданного значения вероятности может быть рассчитано значение квантили (обратный критерий) – значение целевой функции, которое не будет превышено с заданной вероятностью.

Поскольку условием штатного функционирования является непревышение целевой функцией единичного значения, дальнейший алгоритм принятия решения состоит из следующих шагов:

5. Задается значение вероятности α , с которой нам необходимо сделать заключение о возможности дальнейшей эксплуатации (например, $\alpha = 0,95$), после чего с использованием полученного на шаге (4) теоретического закона распределения $F(\Phi)$ определяется значение квантили Φ_α .

6. При выполнении условия $\Phi_\alpha < 1$ принимается решение о возможности дальнейшей эксплуатации, в противном случае принимается решение о запрете дальнейшей эксплуатации и проведения детальной диагностики и, при необходимости – ремонтно-восстановительных работ.

Вычисление вероятностно-гарантированных оценок при отсутствии информации о диапазонах допустимых значений контро-

лируемых параметров. В случае, если информация о диапазонах допустимых значений контролируемых параметров не доступна, ОШФ может быть сформирована на основе выборки значений контролируемых параметров, полученной при достоверно известном штатном функционировании системы. Например, на основе выборки, полученной в некоторый начальный период эксплуатации, когда элементы системы ещё не имеют износа, либо в любой другой период при наличии достоверного заключения технических специалистов об исправном состоянии системы.

На основании такой выборки может быть сформирован гиперпараллелепипед, аналогичный рассмотренному в предыдущем разделе. В качестве границ параллелепипеда могут использоваться минимальное и максимальное выборочное значение каждого из параметров, либо процентиля. Дальнейший алгоритм вычисления оценки состояния также аналогичен рассмотренному ранее.

Другим вариантом представления ОШФ может быть многомерный корреляционный эллипсоид [2]. В n -мерном пространстве контролируемых параметров такой эллипсоид описывается соотношением (6).

$$(X - m_X)^T K_X^{-1} (X - m_X) = R^2 \quad (6)$$

Параметрами эллипсоида являются его центр, в качестве которого используется выборочная оценка вектора математического ожидания вектора контролируемых параметров, и ковариационная матрица, элементами которой являются выборочные оценки ковариаций между контролируемыми параметрами. Выборочные оценки рассчитываются на основе выборки значений контролируемых параметров, полученной при достоверно известном штатном функционировании системы. Для определения характерного размера R ОШФ на основании этой же выборки может быть рассчитана выборка расстояний Махаланобиса от центра эллипсоида до точек, образующих выборку. В качестве границы области может использоваться максимальное значение в полученной выборке расстояний, либо некоторый процентиль.

Для оценки степени принадлежности вектора контролируемых параметров корреляционному эллипсоиду будем использовать расстояние Махаланобиса от центра эллипсоида до точки, соответствующей значениям контролируемых параметров, рассчитываемые на основе соотношения (7).

$$d_i(X(t_i)) = \sqrt{(X - m_X)^T K_X^{-1} (X - m_X)}. \quad (7)$$

В этом случае условие, отражающее степень принадлежности вектора контролируемых параметров эллипсоиду, имеет вид (8).

$$d_i(X(t_i)) < R. \quad (8)$$

Преимуществом представления ОШФ в виде многомерного корреляционного эллипсоида является учёт корреляционных связей между контролируемыми параметрами, характер которых может меняться по мере износа системы. Такое изменение будет влиять на способность системы удерживать значения контролируемых параметров внутри ОШФ и проявляться в значениях расстояния Махаланобиса, и при проверке условия (8).

С учетом изложенного при представлении ОШФ многомерным корреляционным эллипсоидом с параметрами, рассчитанными по выборке при достоверно известном штатном функционировании системы, алгоритм оценки состояния системы и принятия решения о её дальнейшей эксплуатации состоит из следующих шагов.

1. На основании сформированной к текущему моменту эксплуатации выборку X^N формируется выборка d^N расстояний Махаланобиса до центра корреляционного эллипсоида;

2. На основании выборки d^N рассчитывается выборка Φ^N значений критериальной функции, в качестве которой используется расстояние Махаланобиса;

Шаги 3–6 аналогичны рассмотренным в предыдущем разделе с учетом того, что в качестве критериальной функции используется расстояние Махаланобиса, а в качестве граничного значения квантили, которое не должно быть привешено для принятия решения о возможности дальнейшей эксплуатации, используется характерный размер доверительного эллипсоида R .

Прогноз отказов систем

с использованием вероятностно-гарантирующего подхода

Будем предполагать, что результате мониторинга технического состояния системы на некотором периоде её эксплуатации получена выборка значения квантили распределения целевой функции




Рис. 3. Результаты прогноза отказа турбовентиляторного двигателя

Φ_{α}^M , состоящая из значений $\Phi_{\alpha}(t_i)$, характеризующих состояние системы в каждый из M моментов времени t_i .

Прогноз отказа осуществляется путём аппроксимации временного ряда $\Phi_{\alpha}(t)$ какой-либо теоретической зависимостью с последующей экстраполяцией на будущий период и расчетом момента времени, в который квантиль распределения целевой функции превысит граничное значение, используемое для принятия решения о возможности дальнейшей эксплуатации.

На рис. 3 представлены результаты прогноза отказа турбовентиляторного двигателя летательного аппарата с использованием предложенного вероятностно-гарантирующего подхода и данных о моделировании процессов функционирования двигателя [3].

В рассматриваемом примере в соответствии с исходными данными, отказ двигателя произошел на 202-м цикле его эксплуатации. При этом уже за 10 циклов до этого прогнозировался отказ на 204-м цикле, а за 5 циклов прогнозируемое значение точно совпало с фактическим.

Заключение

В работе рассмотрен подход к оценке состояния и прогнозу отказов технических систем и их элементов, использующий в качестве исходных данных параметрическую информацию, накапливаемую в процессе эксплуатации и позволяющий получать гарантированные по вероятности оценки состояния. Преимуществом предложенного подхода является отсутствие необходимости использования данных о предшествующих отказах, получение которых зачастую является затруднительным, особенно в системах, к которым предъявляются высокие требования по надежности, и отказы в которых являются редким событием.

Предложены подходы к построению областей, характеризующих штатное функционирование системы и используемых для оценки состояния, в пространстве контролируемых параметров системы при различном уровне априорной информированности о свойствах системы. Сформулированы правила формирования

оценок текущего состояния и условия принятия решения о возможности дальнейшей эксплуатации системы.

Приведены результаты прогноза отказов турбовентиляторного двигателя летательного аппарата, подтверждающие эффективность применения предложенного подхода к решению задач оценки состояния и прогноза отказов.

Библиография

1. Евдокименков В. Н., Красильщиков М. Н., Ратникова Н. И. Оценка текущего состояния воздушного судна и его систем на основе вероятностно-гарантирующего подхода // Известия РАН. Теория и системы управления. — 2003. — № 6. — С. 38–46.
2. Евдокименков В. Н., Ким Р. В., Красильщиков М. Н., Себряков Г. Г. Интеллектуальная поддержка экипажа на основе доверительной модели замкнутой эргатической системы «самолёт-лётчик». — М.: Физматлит, 2019. — 192 с.
3. Электронный ресурс CMAPSS Jet Engine Simulated Data. URL: <https://www.kaggle.com/datasets/palbha/cmapss-jet-engine-simulated-data> Режим доступа: 01.06.2025.

TECHNICAL CONDITION ESTIMATION AND FAILURE PREDICTION OF TECHNICAL SYSTEMS USING A PROBABILISTIC-GUARANTEERING APPROACH

Roman V. Kim

Moscow Aviation Institute (National Research University), Moscow, Russia
kimrv@mai.ru

Abstract. The article proposes an approach to assessing the state of technical systems and predicting their failures. The proposed approach is based on methods for obtaining probability-guaranteed state estimates, which use parametric information recorded during the operation of the system. The rules for forming technical state estimates and the conditions for making a decision on the possibility of further operation of the system are considered. An example of predicting failures of an aircraft turbofan engine is given, confirming the effectiveness of the proposed approach.

Keywords. State estimates, failure prediction, probability estimation, on-condition maintenance.

* * *

ПОВЫШЕНИЕ КАЧЕСТВА РЕГУЛИРОВАНИЯ В УСЛОВИЯХ НЕОПРЕДЕЛЕННОСТИ С ИСПОЛЬЗОВАНИЕМ МОДИФИЦИРОВАННЫХ ЛИНЕЙНЫХ ЗАКОНОВ УПРАВЛЕНИЯ

Копысова Есения Алексеевна

Институт проблем машиноведения Российской академии наук,
Санкт-Петербург, Россия
eseniya.kopysova43@gmail.com

Аннотация. Исследуются подход к синтезу нелинейных законов управления, формируемых путем преобразования линейных законов управления с помощью нечетных нелинейных функций. Ключевой особенностью метода является квазилинейное представление синтезируемого закона управления, что делает возможным использование аппарат линейных матричных неравенств (ЛМН) для оценки устойчивости замкнутой системы. Благодаря итеративному решению ЛМН удалось определить, как области устойчивости, так и допустимые области для начальных условий. Результаты демонстрируют, что применение нелинейного управления приводит к снижению установившейся ошибки в сравнении с линейным управлением.

Ключевые слова: управление, установившейся режим, нечетная функция, линейное матричное неравенство.

Введение

В современной теории управления значительное внимание уделяется разработке нелинейных законов управления, позволяющих улучшить качество регулирования по сравнению с классическими линейными алгоритмами. Одним из результативных подходов является применение нечетных нелинейных функций для модификации линейных законов управления. Например, в работах [1–4] вводятся сигмоидальные функции для ограничения управляющих воздействий, однако их использование сопряжено с ограничени-

ями фазового пространства из-за природы самих функций. Так, исследования [5–6] демонстрируют использование гиперболического тангенса для преобразования закона управления, предложенного в [7], что способствует снижению установившейся ошибки.

Согласно подходу, изложенному в работах [8, 9] линейный закон управления модифицируется путем замены каждой компоненты вектора состояния x_i на нелинейную функцию $x_i^\gamma \cdot \operatorname{sgn}(x_i)$, где $\gamma > 0$. Применение указанного преобразования позволяет ускорить затухание динамики системы и увеличивает скорость сходимости вектора состояния к нулю, обеспечивая при этом меньшую предельную границу отклонения, чем у классического линейного регулятора.

Как следует из анализа работ [1, 4, 8], применение нелинейных функций в управляющих законах, как правило, требует перенастройки параметров регулятора, что может усложнить процесс синтеза, так и практическую реализацию. Однако проблема построения нелинейных законов управления на основе уже существующих линейных регуляторов без изменения их параметров настройки в указанных публикациях не рассматривалась. Также не рассматривалась возможность повышения точности в устранившемся режиме посредством такого преобразования.

Поэтому, основываясь на результатах, представленных в [10–12] в данной работе предлагается общий метод синтеза нелинейного закона управления. Этот подход позволяет добиться большей точности в установившемся режиме относительно традиционного линейного управления без применения нелинейностей. В отличие от известных подходов, в работе рассматривается модификация линейного регулятора без изменения его настроечных параметров — весь линейный закон управления пропускается через нечетную нелинейную функцию, что позволяет сохранить структуру исходного регулятора и упрощает его внедрение в существующие системы.

Постановка задачи

Рассмотрим динамическую систему, описываемую линейным дифференциальным уравнением:

$$\dot{x} = Ax + Bu + Df, \quad (1)$$

где $x = \text{col}\{x_1, \dots, x_n\}$ – вектор состояния, $u \in \mathbb{R}$ – сигнал управления, $f \in \mathbb{R}^l$ – неизвестное возмущение, удовлетворяющее ограничению $|f| \leq \bar{f}$, A , B и D известны и имеют соответствующие размерности, пара (A, B) является управляемой.

Согласно результатам, изложенным в [5], существует матрица $K = [k_1, \dots, k_n]$, позволяющая использовать линейный закон управления

$$u = Kx = k_1 x_1 + \dots + k_n x_n, \quad (2)$$

при котором выполняется предельное неравенство

$$\lim_{t \rightarrow \infty} |x(t)| \leq \delta, \quad (3)$$

где $\delta > 0$ – ошибка регулирования в установившемся режиме.

В рамках исследования применена нечётная функция $\varphi(\cdot)$. Учитывая выражения (2), синтезирован новый закон управления следующего вида:

$$u = \varphi(k_1 x_1 + \dots + k_n x_n). \quad (4)$$

Необходимо определить ограничения на нелинейную функцию $\varphi(\cdot)$, при которых закон управления (4), синтезированный на основе матрицы K из (2), обеспечивал выполнение условия (3) с меньшей установившейся ошибкой δ в установившемся режиме, чем в линейном случае (2).

Метод решения. Для исследования закона управления, заданного в формуле (5), функция $\varphi(s)$ была представлена в виде $\varphi(s) = \rho(s)s$, где $\rho(s)$ – нелинейный угловой коэффициент, $s \in \mathbb{R}$. Данное представление иллюстрируется на рис. 1. Предложенный метод позволяет рассматривать нелинейный закон управления (4)




Рис. 1. Графическое представление преобразования функции $\varphi(s)$ в функцию линейного вида с переменным угловым коэффициентом $\rho(s)s$.

аналогично линейному случаю (2), а также применять ЛМН для анализа устойчивости замкнутой системы.

Введем закон управления (4) в уравнение (1) и выразим нелинейную функцию $\varphi(Kx)$ как $\varphi(Kx) = \rho(Kx)Kx$. В результате уравнение замкнутой системы принимает вид:

$$\dot{x} = (A + BK\rho(Kx))x + Df. \quad (5)$$

Теорема 1. Пусть для заданных K в (2) и $\tau_i > 0$ существуют такие значения $0 = \rho_0 < \rho_1 < \dots < \rho_v = \bar{\rho}$, $\chi_i > 0$, $\gamma_i > 0$, $P_i = P_i^T > 0$, что выполняются матричные неравенства

$$\begin{bmatrix} (A + BK\rho_i)^T P_i + P_i (A + BK\rho_i) + \tau_i P_i & P_i D \\ P_i > \gamma_i I & -\chi_i I \end{bmatrix} < 0, \quad (6)$$

Пусть множества $\Psi_i = \{\rho_{i-1}, \rho_i\}$, $i = 1, \dots, v$, определяют вершины нелинейного элемента. Следовательно, можно определить

область устойчивости X , множество допустимых начальных условий X_0 , а также получить верхнюю оценку времени переходного процесса T к области $|x(t)| < \varepsilon$. Эти выражения имеют следующий вид:

$$\chi = \{x \in \mathbb{R}^n : \underline{x} \leq |x_i| \leq \bar{x}, i = 1, \dots, n\}; \quad (7)$$

$$\chi_0 = \left\{x \in \mathbb{R}^n : |x| \leq \bar{x}_0 := \sqrt{\frac{\tau \gamma \bar{x}^2 - 2 \bar{x} \bar{f}}{n^2 \tau \|\bar{P}\|}}\right\}; \quad (8)$$

$$T = \frac{1}{\tau} \ln \frac{\tau |x(0)|^2 \|\bar{P}\| + \bar{x} \bar{f}}{\tau \gamma \varepsilon^2 - \bar{x} \bar{f}}, \quad (9)$$

где значения x и $\bar{x}$ находятся из условия, что для всех $s \in [x; \bar{x}]$:

$$\varphi\left(s \sum_{i=1}^n k_i\right) - \underline{\rho} s \sum_{i=1}^n k_i \geq 0 \text{ и } \varphi\left(s \sum_{i=1}^n k_i\right) - \bar{\rho} s \sum_{i=1}^n k_i \leq 0.$$

Доказательство. Рассмотрим случай, когда все компоненты вектора состояния равны между собой: $x_1 = \dots = x_n = s$. Тогда, если указанные неравенства выполняются для любого $s \in [x; \bar{x}]$ значения $\underline{x}$ и $\bar{x}$ определяют соответственно нижнюю и верхнюю границы множества устойчивости, заданного в виде (7).

Это позволяет ограничить анализ системы на область, где нелинейность $\varphi(\cdot)$ содержится внутри заданного сектора $[\rho, \bar{\rho}]$.

Для анализа устойчивости выберем семейство функций Ляпунова

$$V_i(x) = x^T P_i x, i = 1, \dots, v, \quad (10)$$

и потребуем выполнения условия:

$$\dot{V}_i(x) + \tau_i V_i - \chi_i f^T f < 0, i = 1, \dots, v. \quad (11)$$

Подставляя (5) и (10) в (11), получим

$$x^T \left[(A + BK\rho(Kx))^T P_i + P_i (A + BK\rho(Kx)) \right] x + 2x^T P_i D f + \tau_i x^T P_i x - \chi_i f^T f < 0, i = 1, \dots, v. \quad (12)$$

Вводя вектор $z = \text{col}\{x, f\}$, перепишем это условие в матричной форме:

$$z^T \begin{bmatrix} \Psi_{11,i}(Kx) & P_i D \\ * & -\chi_i I \end{bmatrix} z < 0, \quad (13)$$

где $\Psi_{11,i}(Kx) = (A + BK\rho(Kx))^T P_i + P_i (A + BK\rho(Kx)) + \tau_i P_i$.

Неравенство (12) будет выполняться, если выполняется следующее линейное матричное неравенство

$$\begin{bmatrix} \Psi_{11,i}(Kx) & P_i D \\ * & -\chi_i I \end{bmatrix} < 0, i = 1, \dots, v, \quad (14)$$

Элементы диагональной матрицы $\rho(Kx) \in [\rho_{i-1}, \rho_i]$, откуда следует что ЛМН (14) содержит политопную неопределенность. Согласно [8], достаточно проверить выполнение ЛМН только в вершинах этого интервала $[\rho_{i-1}, \rho_i]$. Отсюда следует устойчивость замкнутой системы (6).

Моделирование

Рассмотрим систему (1) со следующими параметрами:

$$A = \begin{bmatrix} 0 & 1 \\ 1 & 2 \end{bmatrix}, B = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, D = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, \quad (15)$$

где возмущение имеет вид:

$$f(t) = 0,15 [1 + \sin(t) + \text{sat}\{d(t)\}].$$

Здесь $\text{sat}\{\cdot\}$ — функция насыщения, ограничивающая сигнал по уровню, а $d(t)$ — белый шум, смоделированный в MATLAB с мощностью 0,1 и шагом дискретизации 0,1.

Выберем матрицу обратной связи $K = [k_1 k_2] = [-2 -4]$ в линейном законе управления (2), обеспечивающую устойчивость объекта (1). Рассмотрим следующие нелинейные функции:

$$\varphi(s) = \mu \text{sat}(\sigma s), \varphi(s) = \mu \arctan(\sigma s), \varphi(s) = \mu \frac{1 - e^{-0.5\sigma s}}{1 + e^{-0.5\sigma s}}. \quad (16)$$

$$\varphi(s) = \mu s^\lambda, \varphi(s) = \mu \text{sat}(\sigma s^\lambda), \varphi(s) = \mu \arctan(\sigma s^\lambda), \quad (17)$$

$$\varphi(s) = \mu \frac{1 - e^{-0.5\sigma s}}{1 + e^{-0.5\sigma s}}, \quad 0 < \lambda < 1.$$

$$\varphi(s) = s^\lambda + s^{1/\lambda}, \quad 0 < \lambda < 1, \quad \varphi(s) = \mu \frac{9s^2 + 9^{-2}}{s^2 + 1}, \quad 9 > 1. \quad (18)$$

Для функций из класса (16) существует $\rho(0)$, для функций из классов (17) и (18) такой предел не существует.

Для заданных параметров системы (15), значения $\tau = 0,01$ и матрицы обратной связи $K = [-2 \ -4]$, линейные матричные неравенства (ЛМН) из условия (7) являются разрешимыми при значениях углового коэффициента $\underline{\rho} = \rho_0 = 0,53$; $\rho_1 = 0,6$; $\rho_2 = 8$; $\rho_3 = 105526$. Решения существуют и при числе итераций больше 3. Однако, пусть $\bar{\rho} = \rho_3 = 105526$.

На рис. 2 представлены результаты моделирования $|x(t)|$ при $x(0) = [0, 20, 2]^T$.




Рис. 2. Переходный процесс по $|x(t)|$: сравнение линейного (2) и нелинейного (4) законов управления с $\varphi(s)$ из (16) при $\mu = 1$ и $\sigma = 100$. Справа — фрагмент графика в увеличенном масштабе

В исследовании были проанализированы переходные процессы динамической системы при использовании различных нелинейных функций применённых к линейному закону управления. Результаты показали, что нелинейные функции существенно снижают ошибку и улучшают динамику системы.

Заключение

В работе предложен метод построения нелинейных законов управления путем пропускания линейного регулятора через нечётную нелинейную функцию без изменения его параметров. Для анализа устойчивости нелинейная функция представляется в виде линейного элемента с переменным угловым коэффициентом, что позволяет использовать линейные матричные неравенства (ЛМН). В результате многошаговой процедуры решения ЛМН были определены условия на нелинейную функцию, при которых гарантируется устойчивость системы и уменьшение установившейся ошибки по сравнению с линейным управлением. Представленный метод открывает возможности для дальнейшего развития нелинейных алгоритмов управления с улучшенными динамическими и точностными характеристиками.

Библиография

1. Khalil, H. K. Nonlinear Systems 3rd Edition. Michigan State University, East Lansing.
2. Guo, Z., Ping, H., Heng, L., Yu, T., Zuxin, L., Xing-Zhong, X., Wei, W. and Yangmin, L. (2020). Sliding Mode Control: An Incremental Perspective. IEEE Access, volume 8, 20108–20117, <https://doi.org/10.1109/ACCESS.2020.2966772>
3. Liu, Y. and Zhu, Q. (2021). Fuzzy approximation-based adaptive control of nonstrict feedback stochastic nonlinear systems with time-varying state constraints. Adaptive control and signal processing, <https://doi.org/10.1002/acs.3325>
4. Antipov, A. S., Krasnova, S. A. and Utkin, V. A. (2022). Synthesis of invariant nonlinear single-channel tracking systems with sigmoidal feedback with specified tracking accuracy. Automation and Remote Control, 1, 40–66.

5. Антипов А. С., Краснова С. А., Уткин В. А. Синтез инвариантных нелинейных одноканальных систем слежения с сигмоидальными обратными связями с обеспечением заданной точности слежения Большие отклонения в линейных системах при ненулевых начальных условиях // Автоматика и телемеханика.

6. Краснова С. А., Антипов А. С. Иерархический синтез сигмоидальных обобщенных моментов манипулятора в условиях неопределенности // Проблемы управления. — 2016. — № 4. — С. 10–21.

7. Краснова С. А., Уткин В. А. Каскадный синтез наблюдателей состояний динамических систем. — М.: Наука, 2006.

8. Nekhoroshikh, A. N., Efimov, D., Polyakov, A., Perruquetti, W. and Furtat, I. B. On finite-time stabilization of a class of nonlinear time-delay systems: Implicit Lyapunov-Razumikhin approach, Proc. IEEE Conference on Decision and Control, 2020. P.1975–1980.

9. Rehan, A. and Al-Durra, A. (2020). Design of Sliding Mode Control for Complex Nonlinear Models: A Numerical Approach, IEEE Access, volume 8, 166347–166364, <https://doi.org/10.1109/ACCESS.2020.3022689>.

10. FURTAT I. B. Nonlinear control laws based on linear ones using odd functions // arXiv:2112.14131. 2021. <https://arxiv.org/pdf/2112.14131.pdf>.

11. И. Б. Фуртат, П. А. Гущин, Е. А. Копысова. “Нелинейные законы управления, построенные на базе линейных с использованием нечетных функций”, УБС, 102 (2023), 58–75 <https://doi.org/10.25728/ubs.2023.102.4>

12. Furtat I., Gushchin P. V., Kopysova E. Nonlinear output feedback control laws based on linear ones for improving ultimate bound // Journal of the Franklin Institute. 2024. Vol. 361. No. 4. p. 106636. <https://doi.org/10.1016/j.jfranklin.2024.01.037>

IMPROVING THE QUALITY OF REGULATION UNDER UNCERTAINTY USING MODIFIED LINEAR CONTROL LAWS

Eseniya A. Kopysova

Institute for Problems in Mechanical Engineering of the Russian Academy of Sciences, St. Petersburg, Russia
eseniya.kopysova43@gmail.com

Abstract. This study examines an approach to synthesizing nonlinear control laws through transformation of linear control laws using odd nonlinear functions. The method's key feature is its quasi-linear representation of the synthesized control law, enabling application of linear matrix inequality (LMI) techniques for closed-loop stability analysis. Through an iterative LMI solution procedure,

we determined stability regions and admissible domains for initial conditions. Results demonstrate that the nonlinear control achieves reduced steady-state error compared to linear control.

Keywords. Control, steady-state regime, odd function, linear matrix inequality.

* * *

УДК 004.8

doi:10.18720/SPBPU/2/id25-540

ПРИМЕНЕНИЕ ОНТОЛОГИЙ НА ОСНОВЕ МЕТА-АССОЦИАТИВНЫХ ГРАФОВ В ЗАДАЧАХ ПРОМЫШЛЕННОГО МАШИННОГО ОБУЧЕНИЯ

Мисник Антон Евгеньевич

Белорусско-Российский университет, г. Могилёв, Республика Беларусь
anton@misnik.by

Аннотация. Статья посвящена применению онтологий, построенных на основе мета-ассоциативных графов, для решения задач машинного обучения, актуальных в промышленности. Рассматриваются интеллектуальный анализ производственных данных, предиктивное обслуживание оборудования, контроль качества и автоматизация принятия решений. Особое внимание уделено тому, как онтологии на основе мета-ассоциативных графов позволяют создавать адаптивные модели и интегрировать разнородные источники данных, повышая эффективность производственных процессов. В работе описана методология построения таких онтологий и их использования совместно с алгоритмами машинного обучения. Приведен пример внедрения на предприятии «Дозатор-плюс» (г. Могилев), демонстрирующий практические преимущества предложенного подхода.

Ключевые слова. Онтологии, машинное обучение, мета-ассоциативные графы.

Введение

Машинное обучение является основным инструментом для анализа больших данных и извлечения из них ценной информа-

ции. К актуальным задачам промышленного применения машинного обучения относятся:

- интеллектуальный анализ производственных данных (поиск скрытых закономерностей и аномалий в технологических процессах);
- предиктивное обслуживание оборудования (прогнозирование отказов станков и агрегатов для предупреждения простоев);
- контроль качества (автоматическое выявление дефектов продукции и причин их возникновения);
- автоматизация принятия решений (системы, способные рекомендовать или самостоятельно принимать решения на основе данных).

Несмотря на успехи в применении методов машинного обучения, промышленная практика сталкивается с проблемой интеграции разрозненных источников данных и учета экспертных знаний. Данные поступают из различных систем и датчиков в разных форматах, а их значение часто понятно только в контексте специфической предметной области. Обычные алгоритмы машинного обучения не обладают встроенным пониманием этого контекста, что может приводить к поверхностным выводам моделей либо требовать огромных объемов размеченных данных для обучения. Онтологии предоставляют способ формализовать знания о предметной области и связать между собой данные из разных источников на концептуальном уровне. Онтология представляет собой точную спецификацию некоторой предметной области: описание сущностей, их свойств и взаимоотношений. Благодаря онтологиям разнородные данные приводятся к единой семантической модели. Онтологический подход повышает интероперабельность данных и позволяет алгоритмам машинного обучения учитывать семантику (смысл) данных, а не только статистические закономерности. Разработка онтологий для сложных производственных систем является сложной задачей, поскольку нужно учесть множество типов объектов, процессов и связей. В этом контексте перспективным инструментом выступают мета-ассоциативные графы, которые позволяют гибко представить сложные структуры знаний.

Мета-ассоциативные графы

Мета-ассоциативные графы расширяют возможности традиционных графовых онтологий [1, 2], вводя дополнительный уровень абстракции и гибкости. Эта структура позволяет динамически ассоциировать и рекомбинировать компоненты онтологии. С использованием мета-ассоциативных графов онтологии могут быть быстро реструктурированы для отражения изменений в системе или её операционной среде, облегчая более отзывчивое и эффективное управление системой.

Мета-ассоциативные графы обобщают понятия вершины и метавершины до понятия узла метаграфа (N), а также дополняют определение узла именем, множеств ассоциативных атрибутов и наборами событий и методов, принадлежащих узлу [3]:

$$N = \{I, AS, EV, M\},$$

где I — имя узла, EV — множество событий, связанных с узлом метаграфа, M — множество методов, связанных с узлом метаграфа, AS — множество ассоциативных атрибутов, которые являются либо обычными атрибутами, либо ссылками на узлы метаграфа:

$$AS = \{A, N^*\}.$$

Данная разновидность метаграфа позволяет повысить гибкость онтологического инжиниринга, в частности, инжиниринга онтологий процессов сложной системы, поскольку ссылки на узлы метаграфа, по сути, мало чем отличаются от ребер метаграфа и позволяют обеспечить ассоциативные связи. Любая вершина потенциально становится метавершиной, так как ссылка на другой узел метаграфа предоставляет все возможности для взаимодействия с ним. С другой стороны, если нет необходимости в конкретный момент использовать ассоциативную связь, то ссылку можно воспринимать в виде обычного атрибута со значением, равным имени узла [4].

Мета-ассоциативные графы обеспечивают интеграцию процессного компонента в фундаментальную онтологическую модель




Рис. 1. Мета-ассоциативный граф

системы. Данный подход предоставляет возможность гибкого и ресурсоэффективного проектирования процессных моделей на базе сегментированной структуры, то есть подграфов, которые составляют единую онтологическую модель, что обеспечивает методологический инструментарий для обеспечения моделей машинного обучения исходными данными, одновременно реализуя функции потребителя и хранилища результатов работы моделей [5].

Методология применения онтологий на основе мета-ассоциативных графов в задачах машинного обучения

Предлагаемый подход к интеграции онтологий и машинного обучения строится вокруг онтологической модели на основе мета-ассоциативного графа, которая служит объединяющим звеном между разнородными данными и алгоритмами анализа. Ключевые этапы и компоненты методологии:

1. Анализ предметной области и разработка онтологии. Совместно с экспертами предприятия выделяются основные сущности и процессы предметной области. Разрабатывается онтологическая модель на основе мета-ассоциативного графа: определяется иерар-

хия классов, атрибуты и связи. Единым узлом знания могут быть представлены сложные отношения — например целый технологический процесс, связывающий несколько входных параметров, конкретное оборудование и выходной показатель качества. Такая структура позволяет описывать обобщенные зависимости (минимизируя число шагов для получения ключевой информации) и при необходимости детализировать их (раскрывая все связанные компоненты и данные). Онтология формализуется в виде базы знаний, готовой к наполнению актуальной информацией.

2. Интеграция разнородных данных. После разработки онтологии выполняется привязка существующих источников данных к ее понятийному аппарату. Данные с сенсоров, журналы обслуживания, результаты контроля качества и другие информационные потоки проецируются на соответствующие классы и свойства онтологии. При получении и распределении данных активно используется процессная составляющая инструментария мета-ассоциативных графов, способная реагировать на изменения его структуры и атрибутов. В итоге разнородная информация интегрируется в едином семантическом пространстве, и алгоритмы машинного обучения получают доступ к полному контексту данных.

3. Разработка и обучение моделей машинного обучения. На основе сформированной совокупности данных и знаний разрабатываются модели машинного обучения под целевые задачи. Онтология при этом используется двояко. Во-первых, для извлечения признаков и подготовки обучающих выборок (добавляются семантические признаки: тип оборудования, важность параметра, недавние события обслуживания и т. п.). Во-вторых, для наложения априорных ограничений или правил на модель (например, известные физические пределы параметров могут ограничивать пространство решений при обучении). Выбираются алгоритмы, подходящие для каждой задачи: для интеллектуального анализа данных — методы классификации или кластеризации с учетом семантики; для предиктивного обслуживания — модели прогностической аналитики (например, случайный лес или нейросеть, предсказывающие вероятность отказа); для контроля качества — алгоритмы обнаруже-

ния аномалий или распознавания дефектов, обогащенные знаниями о допустимых диапазонах параметров. Модели обучаются на исторических данных предприятия, аннотированных посредством онтологии, что повышает достоверность и релевантность обучающих выборок [6,7].

4. Внедрение модели и онтологии в эксплуатацию. Обученные модели интегрируются в информационную систему предприятия наряду с онтологической базой знаний. При поступлении новых данных они немедленно сопоставляются с соответствующими элементами онтологии и передаются на вход модели машинного обучения. Предсказания модели затем интерпретируются с учетом знаний, содержащихся в онтологии. Онтология и модель функционируют в связке, обеспечивая понятную и целенаправленную выдачу результатов.

5. Адаптивное обновление знаний и моделей. После внедрения система функционирует в режиме постоянного самообучения. Онтология и модели актуализируются по мере поступления новых данных. При появлении новых типов оборудования или продукции онтологическая модель расширяется соответствующими классами и свойствами. Модели машинного обучения переобучаются (либо дообучаются) на новых данных, чтобы учитывать изменения в системе и среде. Выявленные алгоритмами новые закономерности проверяются экспертами и при подтверждении вносятся в онтологию в виде дополнительных правил или отношений. Такой адаптивный цикл гарантирует актуальность системы: она подстраивается под изменения в производстве и накапливает всё больше знаний о процессах предприятия.

Пример промышленного применения методологии

В качестве практического кейса рассмотрим предприятие СООО «Дозатор-плюс» (г. Могилев, Республика Беларусь), более 20 лет занимающееся выпуском насосов-дозаторов рулевого управления (гидравлических распределителей для систем гидроусилителя руля) преимущественно для сельскохозяйственной и

строительной техники. На заводе используется современное металлообрабатывающее оборудование (станки с ЧПУ, обрабатывающие центры) и автоматизированные линии сборки, а также испытательные стенды для контроля характеристик готовых изделий. Выпускаемая продукция критична по качеству и надежности, поэтому предприятие заинтересовано в минимизации дефектов и простоев оборудования, переходя от реагирования на проблемы к их предупреждению с помощью анализа данных.

На «Дозатор-плюс» была разработана онтология производственного процесса, охватывающая основные понятия: **продукция** (модели насосов-дозаторов и их составные узлы), **оборудование** (станки, прессы, сборочные и испытательные стенды), **технологические операции** (фрезеровка корпуса, термообработка, сборка узла, тестирование), **параметры** (давление, расход, температура, вибрация и др.), а также **события** (смены, плановое ТО, неисправности, результаты испытаний). Связи в онтологической модели отражают структуру изделия (иерархию компонентов), маршруты технологического процесса (последовательность операций и соответствующее им оборудование) и причинно-следственные зависимости (влияние отклонения параметров процесса на появление дефекта). Организация знаний на основе мета-ассоциативных графов позволила представить целые подпроцессы единой сущностью: например, операция сборки оформлена как один узел графа, объединяющий данные о станке, операторе, деталях и контролируемых параметрах, что позволяет рассматривать её интегрированно при анализе.

Интеграция данных предприятия с созданной онтологией связала воедино ранее разрозненную информацию. Датчики вибрации и температуры, установленные на ключевых станках, были подключены к системе: их показания автоматически привязываются к соответствующим узлам онтологии. Исторические журналы простоев и ремонтов за несколько лет импортированы в базу знаний, причем каждая запись маркируется ссылкой на конкретное оборудование и тип инцидента. Учтены результаты финального тестирования продукции: для каждого выпущенного насоса соз-

дается экземпляр класса «Изделие» с сохраненными параметрами испытаний (давление, производительность и т.д.) и отметкой о том, пройден ли тест успешно или зафиксирован дефект. В итоге все разрозненные факты – от показаний датчика до записи о браке – объединились в едином информационном пространстве, где их можно легко связывать и анализировать.

После формирования базы знаний и загрузки данных были разработаны несколько моделей машинного обучения для задач предприятия. Например, для **предиктивного обслуживания** оборудования применена модель, прогнозирующая вероятность отказа станков на основе динамики их сенсорных показателей и истории инцидентов. Для токарного станка, обрабатывающего корпус насоса, анализируются тренды вибрации шпинделя и температуры подшипников, увязанные с наработкой (моточасами) и давностью последнего обслуживания. Онтология интерпретирует сырые сигналы в понятиях предметной области – модель получает на вход не просто время и величину вибрации, а признаки вроде «вибрация превышает норму для узла типа X» или «температура растет быстрее типичного профиля». В результате модель способна заблаговременно (за несколько дней или недель) выявлять аномальное состояние, указывающее на приближающуюся неисправность, и идентифицировать вероятную причину (например, износ подшипника шпинделя). Это позволило перейти от реагирования на поломки к планово-предупредительным ремонтам: система заранее формирует заявку или рекомендацию на обслуживание узла в удобное для производства время, вместо того чтобы допустить аварийный простой в разгар смены.

Заключение

Использование онтологий на основе мета-ассоциативных графов в сочетании с методами машинного обучения позволяет вывести решение производственных задач на новый уровень. Предложенный подход интегрирует разнородные данные в единую модель знаний, что дало возможность создавать адаптивные алгоритмы,

учитывающие контекст и экспертные зависимости. На примере предприятия «Дозатор-плюс» показано, что такой подход приводит к осязаемому снижению простоев, повышению качества продукции и общей эффективности процессов за счет проактивного анализа данных и автоматизированной поддержки решений.

Дальнейшее развитие подобной комбинации данных и знаний будет способствовать появлению всё более автономных «умных» производств, соответствующих концепции Индустрии 4.0. Онтологические модели могут стать ядром цифровых двойников и систем предиктивного управления, в которых решения в реальном времени принимаются на базе накопленных и формализованных знаний. Практическое внедрение этих технологий уже сегодня повышает конкурентоспособность предприятий и формирует новую культуру управления, основанную на данных и знаниях.

Библиография

1. Chernenkiy, VM, Gapanyuk, Yu. E., Revunkov, GI, Andreev, AM, Kaganov, Yu. T., Dunin, IV: The Principles and the Conceptual Architecture of the Metagraph Storage System. In: Manolopoulos, Ya., Stupnikov, S. (eds.) 20th International Conference, DAMDID/RCDL 2018, Revised Selected Papers, CCIS, vol. 1003, pp. 73-87.
2. Gapanyuk Yu. E. Metagraph Approach to the Information-Analytical Systems Development. In: Proceedings of the 6th International Conference Actual Problems of System and Software Engineering, Moscow, Russia, 2019, pp. 428-439.
3. A. E. Misnik. "Ontological Engineering on Metagraphs Basis," 2022 VI International Conference on Information Technologies in Engineering Education (Inforino), Moscow, Russian Federation, 2022, pp. 1-6, doi: 10.1109/Inforino53888.2022.9782909.
4. Borisov, V.V., Misnik, A. E. (2023). Ontological Engineering of Interrelated Processes in Complex Cyber-Physical Systems. In: Kovalev, S., Sukhanov, A., Akperov, I., Ozdemir, S. (eds) Proceedings of the Sixth International Scientific Conference "Intelligent Information Technologies for Industry" (ITI'22). ITI 2022. Lecture Notes in Networks and Systems, vol 566. Springer, Cham. https://doi.org/10.1007/978-3-031-19620-1_39
5. Моделирование образовательных процессов на основе нейронечетких темпоральных сетей Петри / В. В. Борисов, А. Е. Мисник, С. А. Про-

копенко [и др.] // Прикладная информатика. — 2021. — Т. 16, № 4(94). — С. 35–7. — DOI 10.37791/2687-0649-2021-16-4-35-47. — EDN AWVDXP.

6. **Борисов, В. В.** Способ оперативного управления на основе комбинированного моделирования / В. В. Борисов, А. Е. Мисник // Научное обозрение. — 2014. — № 1. — С. 117–122. — EDN SBOIHB.

7. **Borisov, V. V. and A. E. Misnik.** “Combined neural network modeling method for the operational management of complex systems.” Information technologies 7 (2012): 69–72.

APPLICATION OF ONTOLOGIES BASED ON META-ASSOCIATIVE GRAPHS TO INDUSTRIAL MACHINE-LEARNING TASKS

Anton E. Misnik

Belarusian-Russian University, Mogilev, Republic of Belarus
anton@misnik.by

Abstract. This paper investigates the use of ontologies based on meta-associative graphs to address industry-relevant machine-learning problems. The study focuses on intelligent analysis of manufacturing data, predictive maintenance, quality assurance, and automated decision-making. Particular emphasis is placed on how meta-associative-graph ontologies support the creation of adaptive models and the seamless integration of heterogeneous data sources, thereby enhancing production efficiency. The article details the methodology for building such ontologies and coupling them with machine-learning algorithms. A case study at Dozator-Plus (Mogilev, Belarus), illustrates the practical benefits of the proposed approach.

Keywords. Ontologies, machine learning, meta-associative graphs.

* * *

УДК 330.1

doi:10.18720/SPBPU/2/id25-541

АВТОМАТИЧЕСКАЯ ГЕНЕРАЦИЯ 3D-МОДЕЛЕЙ ПОМЕЩЕНИЙ НА ОСНОВЕ ПЛАНИРОВОК С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Паращук Дмитрий Иванович^{1,2,а}, Карякин Юрий Евгеньевич^{2,б}

¹АО «СОЛАР СЕКЬЮРИТИ», г. Тюмень, Россия

²Тюменский государственный университет, г. Тюмень, Россия

^аparashchuk.dmitrii@gmail.com, ^бmailto: y.e.karyakin@utmn.ru

Аннотация. В данной работе разработано решение для автоматической генерации 3D-моделей помещений на основе 2D-планировок с применением методов искусственного интеллекта. Основной задачей была выбрана сегментация стен, так как они определяют основную структуру помещения, необходимую для создания точной 3D-модели [2, 3, 7, 8]. Для решения сформирован набор данных из планировок, содержащий 700 изображений с применением аугментаций, таких как обрезка, поворот и изменение цветового тона. Исследованы архитектуры нейронных сетей UNetPlusPlus [10], DeepLabV3Plus [9], FPN [4] и PSPNet [9] с различными энкодерами: efficientnet [5], resnet [6] и mobilenet, а также протестированы функции потерь, включая LovaszLoss [1], FocalLoss, DiceLoss и их комбинации. Лучшие модели объединены в ансамбль для повышения точности распознавания стен. Для очистки полученных масок были применены морфологические операции. В результате решение позволяет построить 3D-модели помещений, с возможностью экспорта для дальнейшей доработки. В статье описан выбор методов, процесс построения моделей и результаты экспериментов, а также сделаны выводы о возможностях применения разработанного подхода.

Ключевые слова. 3D-моделирование помещений, 2D-планировки, глубокое обучение, семантическая сегментация, ансамблевое обучение, распознавание стен, сверточные нейронные сети.

Введение

Автоматическое создание 3D-моделей помещений на основе 2D-планировок представляет собой актуальную задачу в области

компьютерного зрения и обработки изображений [2, 3, 7, 8]. Планировки помещений, представленные в виде схематичных чертежей, содержат информацию о структуре пространства, однако их преобразование в трехмерные модели при ручной обработке требует значительных временных и финансовых затрат. Ручное моделирование не только трудоемко, но и дорого, что ограничивает его применение в крупных проектах или при использовании пользователями в своих нуждах. Автоматизация этого процесса позволяет снизить затраты, ускорить создание 3D-моделей для показа на сайтах застройщиков или упростить составление проектов для личных целей.

Традиционные инструменты, такие как Autodesk Revit, AutoCAD, SketchUp или Archicad, предназначены для ручного моделирования или BIM-проектирования и не поддерживают автоматическое создание 3D-моделей из 2D-планировок. Эти программы требуют от пользователей значительных усилий и профессиональных навыков, что делает их неподходящими для автоматизации.

Основной задачей исследования является разработка метода сегментации стен на 2D-планировках, поскольку стены определяют геометрическую структуру помещения, необходимую для построения точной 3D-модели. Сегментация стен осложняется необходимостью адаптации к различным видам входных данных: планировки могут быть представлены в виде четких чертежей, низкокачественных сканов или изображений с дополнительными элементами, такими как мебель или текстовые аннотации. Для решения этой задачи применены методы глубокого обучения, в частности, сверточные нейронные сети, которые эффективно выделяют стены на изображениях благодаря способности извлекать пространственные и контекстные признаки из сложных визуальных данных [2, 3, 7, 8]. Исследованы архитектуры UNetPlusPlus [10], DeepLabV3Plus [9], FPN [4] и PSPNet [9] с различными энкодерами efficientnet [5], resnet [6], mobilenet и функциями потерь DiceLoss, FocalLoss, LovaszLoss [1] и их комбинации для достижения высокой точности.

Разработанное решение позволяет построить 3D-модель помещения с высокой точностью благодаря использованию ансамбля моделей, что поддерживает обработку разнообразных планировок, включая изображения низкого качества. **Обучающий набор данных был сформирован с применением преобразований, таких как изменение масштаба, поворот и корректировка цветовых характеристик, что повышает устойчивость** модели к различным видам планировок. На основе полученных масок стен формируются 3D-модели, которые могут быть экспортированы в различные форматы с возможностью дальнейшей доработки. Решение применимо для создания визуализаций помещений на сайтах застройщиков, проектирования интерьеров, использования в BIM-программах или интеграции в системы виртуальной реальности. Целью работы является создание наиболее точной нейросетевой модели, которая позволит ускорить процесс построения трехмерных моделей помещений.

Постановка задачи

Описание предметной области. Трехмерные модели позволяют визуализировать структуру помещений и используются при проектировании на этапе ремонта или строительства. Такие модели помогают застройщикам показывать будущие квартиры на сайтах, дизайнерам интерьеров — согласовывать проекты с заказчиками, а строительным компаниям, выполняющим ремонт под ключ, — готовить чертежи и передавать планы бригадам.

Однако создание 3D-моделей вручную требует значительных затрат времени и средств, а также специальных навыков, что усложняет процесс проектирования. При личном использовании отсутствие навыков делает самостоятельное создание моделей практически невозможным. Застройщики, реализующие большое количество квартир, сталкиваются с высокими расходами на разработку множества моделей, что увеличивает стоимость проектов.

Определение проблемы. Автоматизация могла бы существенно упростить процесс создания моделей, однако существующие решения не позволяют эффективно решить задачу в заданных условиях.

Существующие решения на основе глубокого обучения, которые могли бы генерировать модели автоматически, как правило, ориентированы на большие наборы данных и не адаптированы к специфическим особенностям российских планировок, включающих уникальные условные обозначения или форматы [2, 3, 7, 8]. Кроме того, такие решения часто являются дорогостоящими западными продуктами, недоступными для небольших компаний или частных пользователей. Бесплатные альтернативы, такие как Blender, также не предлагают готовых инструментов для автоматического преобразования планировок в 3D-модели и требуют сложной настройки.

Малый объем данных, создает дополнительные трудности, так как большинство современных моделей глубокого обучения требуют больших датасетов для достижения приемлемой точности. Отсутствие готовых наборов данных, адаптированных к российским планировкам, еще больше усложняет задачу. Таким образом, проблема сводится к разработке метода, который позволяет автоматически генерировать точные 3D-модели помещений на основе 2D-планировок, используя малый набор данных и учитывая особенности планировок, при этом оставаясь доступным для широкого круга пользователей.

Моделирование системы

Обоснование выбора языка моделирования. Для реализации метода автоматической генерации 3D-моделей на основе 2D-планировок выбран язык программирования Python с использованием фреймворка PyTorch. Python выбран как стандартный инструмент для задач глубокого обучения, обеспечивающий удобство разработки и тестирования моделей. Фреймворк PyTorch с использованием библиотеки segmentation-models-pytorch предоставляет готовые реализации архитектур: UNetPlusPlus [10], DeepLabV3Plus [9], FPN [4] и PSPNet [9], а также энкодеры, включая efficientnet-b4 [5], resnext50_32x4d [6], efficientnet-b3 [5], resnet34 [6] и mobilenet_v2. Это упрощает проведение экспериментов с раз-

личными архитектурами и гиперпараметрами, что критично для достижения высокой точности при ограниченном объеме данных.

Для обработки изображений и постобработки масок (выделение контуров стен и устранения шумов) применялись библиотеки OpenCV и NumPy. Также использовалась библиотека PyVista, которая позволяет создавать и экспортировать трехмерные модели на основе полученных контуров.

В качестве альтернативы рассматривался фреймворк TensorFlow, но PyTorch оказался предпочтительнее из-за наличия предобученных моделей сегментации и встроенных энкодеров.

Построение модели. Процесс построения модели включает подготовку набора данных, обучение нейронных сетей для сегментации стен, постобработку масок и формирование трехмерных моделей. Для подготовки датасета использовался сервис Roboflow, было собрано 700 изображений планировок различных застройщиков. Применялись аугментации: обрезка, поворот и изменение цветового тона, что увеличило разнообразие данных и повысило устойчивость модели к низкокачественным сканам или чертежам с лишними элементами, такими как мебель или надписи.

Обучение нейронных сетей проводилось с использованием библиотеки segmentation-models-pytorch. Исследованы архитектуры UNetPlusPlus [10], DeepLabV3Plus [9], FPN [4] и PSPNet [9] с энкодерами efficientnet-b4 [5], resnext50_32x4d [6], efficientnet-b3 [5], resnet34 [6] и mobilenet_v2. Протестированы функции потерь: DiceLoss, FocalLoss, LovaszLoss [1], а также комбинации CombinedLossDiceFocal и CombinedLossDiceLovasz с коэффициентом $\alpha=0.5$ для балансировки.

Оптимизация и оценка качества сегментации осуществлялись с учетом следующих компонентов:

- **оптимизатор AdamW** – улучшенный алгоритм Adam для регуляризации весов, что стабилизирует обучение;
- **планировщик CosineAnnealingWarmRestarts** – циклически адаптирует скорость обучения по косинусному закону с периодическими перезапусками, улучшая сходимость на малом наборе данных.

А также метрики качества:

- **IoU (Intersection over Union)** – доля пересечения предсказанных и истинных пикселей стен относительно их объединения [1];
- **Dice Coefficient** – мера сходства, учитывающая пересечение предсказанных и истинных областей;

- **Pixel Accuracy** – доля правильно классифицированных пикселей.

Для повышения качества создан ансамбль моделей, объединяющий предсказания лучших конфигураций (UNetPlusPlus [10] и DeepLabV3Plus [9]). Это позволило снизить ошибки отдельных моделей и улучшить общую точность.

Полученные маски были очищены от шумов с использованием библиотеки OpenCV. Применялись морфологические операции с ядром 5x5:

- **дилатация (dilation)**: расширяет области стен;
- **эрозия (erosion)**: устраняет мелкие артефакты;
- **закрытие (closing)**: комбинирует дилатацию и эрозию для сглаживания контуров и заполнения разрывов [2, 3, 7, 8].

На основе обработанных контуров создавались трехмерные модели с использованием библиотеки PyVista. Контуров стен преобразовывались в полигоны со стандартной высотой стен 2.7 метра.

Результаты экспериментов. Для оценки качества сегментации стен были проведены эксперименты на наборе данных из 700 изображений планировок с применением различных архитектур, энкодеров и функций потерь. Обучение выполнялось до 15 эпох с ранней остановкой при отсутствии улучшения IoU в течение 3 эпох. Качество моделей оценивалось по метрике IoU (Intersection over Union), отражающей долю пересечения предсказанных и истинных пикселей стен относительно их объединения [1].

Протестированы архитектуры UNetPlusPlus [10], DeepLabV3Plus [9], FPN [4] и PSPNet [9] с энкодерами efficientnet-b4 [5], resnext50_32x4d [6], efficientnet-b3 [5], resnet34 [6] и mobilenet_v2. Рассматривались функции потерь: DiceLoss, FocalLoss, LovaszLoss, CombinedLossDiceFocal и CombinedLossDiceLovasz. В табл. 1 приведены результаты для ряда конфигураций, выраженные в значениях IoU на валидационной выборке:

Оценка конфигураций моделей

Архитектура	Энкодер	Функция потерь	Лучший IoU
UnetPlusPlus	resnext50_32x4d	CombinedLossDiceLovasz	0.9016
UnetPlusPlus	resnet34	CombinedLossDiceLovasz	0.9008
UnetPlusPlus	resnet34	LovaszLoss	0.9000
UnetPlusPlus	resnet34	DiceLoss	0.8972
UnetPlusPlus	resnet34	CombinedLossDiceFocal	0.8971
UnetPlusPlus	resnext50_32x4d	FocalLoss	0.8968
UnetPlusPlus	resnet34	FocalLoss	0.8966
UnetPlusPlus	resnext50_32x4d	DiceLoss	0.8941
UnetPlusPlus	efficientnet-b4	CombinedLossDiceLovasz	0.8934
UnetPlusPlus	efficientnet-b4	DiceLoss	0.8925
UnetPlusPlus	efficientnet-b4	CombinedLossDiceFocal	0.8915
UnetPlusPlus	efficientnet-b3	CombinedLossDiceLovasz	0.8910
UnetPlusPlus	resnext50_32x4d	LovaszLoss	0.8905
UnetPlusPlus	efficientnet-b4	LovaszLoss	0.8903
UnetPlusPlus	efficientnet-b3	DiceLoss	0.8900
UnetPlusPlus	efficientnet-b3	CombinedLossDiceFocal	0.8887
UnetPlusPlus	efficientnet-b3	LovaszLoss	0.8872
UnetPlusPlus	efficientnet-b4	FocalLoss	0.8841
UnetPlusPlus	efficientnet-b3	FocalLoss	0.8841
UnetPlusPlus	resnext50_32x4d	CombinedLossDiceFocal	0.8840
DeepLabV3Plus	resnet34	CombinedLossDiceLovasz	0.8827
DeepLabV3Plus	resnet34	LovaszLoss	0.8807
DeepLabV3Plus	resnext50_32x4d	LovaszLoss	0.8791
DeepLabV3Plus	resnext50_32x4d	FocalLoss	0.8769
DeepLabV3Plus	resnext50_32x4d	CombinedLossDiceLovasz	0.8766
DeepLabV3Plus	resnet34	CombinedLossDiceFocal	0.8740

Окончание табл. 1

DeepLabV3Plus	resnext50_32x4d	CombinedLossDiceFocal	0.8736
DeepLabV3Plus	resnet34	FocalLoss	0.8725
DeepLabV3Plus	resnext50_32x4d	DiceLoss	0.8706
DeepLabV3Plus	resnet34	DiceLoss	0.8685
DeepLabV3Plus	efficientnet-b4	DiceLoss	0.8526
DeepLabV3Plus	efficientnet-b4	FocalLoss	0.8505
DeepLabV3Plus	efficientnet-b4	LovaszLoss	0.8500
DeepLabV3Plus	efficientnet-b4	CombinedLossDiceLovasz	0.8499
DeepLabV3Plus	efficientnet-b3	DiceLoss	0.8476
DeepLabV3Plus	efficientnet-b3	FocalLoss	0.8435
DeepLabV3Plus	efficientnet-b3	LovaszLoss	0.8431
DeepLabV3Plus	efficientnet-b3	CombinedLossDiceLovasz	0.8425
DeepLabV3Plus	efficientnet-b4	CombinedLossDiceFocal	0.8342
DeepLabV3Plus	efficientnet-b3	CombinedLossDiceFocal	0.8312
FPN	mobilenet_v2	DiceLoss	0.8203
PSPNet	efficientnet-b3	DiceLoss	0.7513

Анализ результатов

Наилучшие результаты среди отдельных моделей достигнуты для UNetPlusPlus с энкодером resnet34 (IoU=0.9000 с CombinedLossDiceLovasz) и DeepLabV3Plus с энкодером resnet34 (IoU=0.8827 с CombinedLossDiceLovasz). Архитектуры FPN и PSPNet для данной задачи показали низкие результаты.

Сравнение энкодеров показало, что resnet34 обеспечивает качество, сравнимое с более тяжелыми efficientnet-b4 (IoU до 0.8934) и resnext50_32x4d (IoU до 0.9016). Разница в IoU незначительна, что делает resnet34 предпочтительным из-за меньшей вычислительной сложности, снижая требования к ресурсам без потери точности.

Функция потерь CombinedLossDiceLovasz продемонстрировала наилучшие результаты, стабильно улучшая IoU по сравнению

с DiceLoss, FocalLoss, LovaszLoss и CombinedLossDiceFocal. Это обусловлено комбинацией DiceLoss, акцентирующей сходство областей, и LovaszLoss, оптимизирующей метрику IoU напрямую.

Для повышения качества сформирован ансамбль из UNetPlusPlus и DeepLabV3Plus с энкодером resnet34. Разнообразие архитектур позволило моделям компенсировать ошибки друг друга, а усреднение предсказаний увеличило среднее значение IoU до 0.92.




Рис. 1. Пример инференса без мебели



Рис. 2. Пример инференса с мебелью




Рис. 3. Пример экспортированной 3D-модели помещения

Примеры инференсов (с мебелью и без мебели) представлены на рис. 1, 2. Результат экспорта модели после очистки контуров с помощью морфологических операций отображен на рис. 3.

Заключение

Разработанное решение обеспечивает автоматизацию процесса генерации трехмерных моделей помещений на основе двухмерных планировок. Подготовка набора данных с использованием сервиса Roboflow и аугментаций позволила адаптировать модель к низкокачественным изображениям. Обучение нейронной сети с применением библиотеки segmentation-models-pytorch, оптимизатора AdamW и планировщика CosineAnnealingWarmRestarts обеспечило высокую точность сегментации стен. Постобработка масок с морфологическими операциями (дилатация, эрозия, закрытие) устранила шумы и улучшила качество контуров.

Эксперименты показали, что наилучшие результаты достигнуты для архитектур UNetPlusPlus и DeepLabV3Plus с энкодером

resnet34 и функцией потерь CombinedLossDiceLovasz, обеспечивая IoU до 0.9000. Ансамблевый подход, объединяющий эти модели, повысил среднее значение IoU до 0.92, что подтверждает эффективность комбинирования архитектур с различными характеристиками ошибок. Использование resnet34 вместо более тяжелых энкодеров, таких как efficientnet-b4 или resnext50_32x4d, позволило снизить вычислительную сложность без существенной потери качества.

Предложенная нейросетевая модель продемонстрировала высокую точность, и минимизировала ручной труд при создании 3D-моделей. Перспективы дальнейших исследований включают расширение набора данных, тестирование дополнительных архитектур и функций потерь, а также оптимизацию ансамбля для повышения качества сегментации.

Библиография

1. **Berman M., Triki A. R., Blaschko M. B.** The Lovász-Softmax loss: A tractable surrogate for the optimization of the intersection-over-union measure in neural networks // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2018. — P. 4413–4421. <https://arxiv.org/abs/1705.08790>.
2. **Hoang N.-D.** Image Processing-Based Recognition of Wall Defects Using Machine Learning Approaches and Steerable Filters // Computational Intelligence and Neuroscience. — 2018. — Vol. 2018. — Article ID 7913952. <https://doi.org/10.1155/2018/7913952>.
3. **Kim H., Kim S., Yu K.** Automatic Extraction of Indoor Spatial Information from Floor Plan Image: A Patch-Based Deep Learning Methodology Application on Large-Scale Complex Buildings // ISPRS International Journal of Geo-Information. — 2021. — Vol. 10, No. 12. — Article 828. <https://doi.org/10.3390/ijgi10120828>.
4. **Lin T.-Y., Dollar P., Girshick R., He K., Hariharan B., Belongie S.** Feature Pyramid Networks for Object Detection // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2017. — P. 936–944. <https://arxiv.org/abs/1612.03144>.
5. **Tan M., Le Q. V.** EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // International Conference on Machine Learning (ICML). — 2019. — P. 6105–6114. <https://arxiv.org/abs/1905.11946>.

6. Xie S., Girshick R., Dollar P., Tu Z., He K. Aggregated Residual Transformations for Deep Neural Networks // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2017. — P. 5987–5995. <https://arxiv.org/abs/1611.05431>.

7. Yan Y., Li C., Zhang Y. Floor Plan Semantic Segmentation Using Deep Learning with Boundary Attention Aggregated Mechanism // IEEE Access. — 2022. — Vol. 10. — P. 104923–104934. <https://doi.org/10.1109/ACCESS.2022.3207769>

8. Yu C., Li C., Li S.-G. Research on Image Recognition of Building Wall Design Defects Based on Partial Differential Equation // Advances in Mathematical Physics. — 2021. — Vol. 2021. — Article ID 6660939. <https://doi.org/10.1155/2021/6660939>

9. Zhao H., Shi J., Qi X., Wang X., Jia J. Pyramid Scene Parsing Network // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2017. — P. 6230–6239. <https://arxiv.org/abs/1612.01105>

10. Zhou Z., Siddiquee M. M. R., Tajbakhsh N., Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. — 2018. — P. 3–11. <https://arxiv.org/abs/1807.10165>

AUTOMATIC 3D ROOM MODEL GENERATION FROM FLOOR PLANS USING ARTIFICIAL INTELLIGENCE

Dmitriy I. Parashchuk^{1,2,a}, Yuri E. Karyakin^{2,b}

¹JSC Solar Security, Tyumen, Russia,

²Tyumen State University, Tyumen, Russia,

^aparashchuk.dmitrii@gmail.com, ^by.e.karyakin@utmn.ru

Abstract. This paper develops a solution for the automatic generation of 3D models of indoor spaces based on 2D floor plans using artificial intelligence methods. The segmentation of walls was chosen as the primary task, as they define the core structure of a space, essential for creating an accurate 3D model [2, 3, 7, 8]. To address this, a dataset of floor plans was compiled, containing 700 images augmented with techniques such as cropping, rotation, and hue adjustment. Several neural network architectures, namely UNetPlusPlus [10], DeepLabV3Plus [9], FPN [4], and PSPNet [9], were investigated with various encoders: efficientnet [5], resnet [6], and mobilenet. Different loss functions, including LovaszLoss [1], FocalLoss, DiceLoss, and their combinations, were also tested. The best-performing models were combined into an ensemble to

enhance the accuracy of wall segmentation. Morphological operations were applied to refine the resulting masks. As a result, the solution enables the creation of 3D models of indoor spaces, which can be exported for further processing. The paper describes the selection of methods, the model-building process, experimental results, and provides conclusions on the potential applications of the developed approach.

Keywords. 3D-room modeling, 2D floor plans, deep learning, semantic segmentation, ensemble learning, wall detection, convolutional neural networks, artificial intelligence.

* * *

УДК 004.89:004.93

[doi:10.18720/SPBPU/2/id25-542](https://doi.org/10.18720/SPBPU/2/id25-542)

КЛАСТЕРИЗАЦИЯ И ПРЕДОБРАБОТКА ДАННЫХ В УПРАВЛЕНИИ РЕАБИЛИТАЦИЕЙ

Арсеньев Дмитрий Германович^{1,a}, Мисник Антон Евгеньевич^{2,6},
Шалухова Мария Александровна^{2,b}

¹Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

²Белорусско-Российский университет,
г. Могилев, Республика Беларусь

^aarsenjevasp@yandex.ru, ⁶anton@misnik.by, ^bshaluhova.m@yandex.ru

Аннотация. В работе рассматривается вопрос повышения качества управления реабилитацией, а также точности прогнозов и выводов, формируемых интеллектуальной системой поддержки принятия решений. Предлагается подход, основанный на совершенствовании алгоритма предобработки пользовательских данных, получаемых с помощью модуля компьютерного зрения. Отмечается проблема низкого качества исходной информации, поступающей в систему. Для её решения предлагается комбинация методов, включающая стабилизацию видеоряда, нормализацию данных и вейвлет-преобразование, что в совокупности улучшает качество итогового анализа. Для последующей кластеризации пациентов используются ANFIS-подобные нейро-нечеткие сети, что обеспечивает высокую точность персонализированных реабилитационных рекомендаций. Предложенный подход повышает эффективность реабилитацион-

ных мероприятий, делая их более адаптированными к индивидуальным потребностям пациентов, а также способствует автоматизации процессов управления реабилитацией.

Ключевые слова. Кластеризация, компьютерное зрение, нейронные сети, предобработка данных, управляющие системы, вейвлет-преобразования, ANFIS-подобные нейронные сети.

Введение

Интеграция данных компьютерного зрения в интеллектуальные системы поддержки принятия решений (СППР) и системы управления открывает новые перспективы во многих прикладных сферах. Такие системы, основанные на сборе и анализе данных, полученных средствами компьютерного зрения, способны удовлетворять потребности в персонализированном подходе, мониторинге и ранней диагностике, используя дополнительные аналитические модули и прогнозируя риски [1, 2, 5].

При прогностической оценке динамики процесса, и оценке возникновения рисков системой, особую значимость приобретает разработка методов предобработки и оптимизации получаемых данных. Корректная предварительная обработка, сохраняющая ключевые признаки наблюдаемых объектов, обеспечивает надёжность дальнейших аналитических выводов [7].

При разработке системы управления реабилитацией необходимо учитывать, что для объективной оценки функционального состояния опорно-двигательного аппарата пациента приходится сталкиваться с уникальными анатомическими особенностями каждого человека. Кроме того, качество изображений, получаемых в ходе мониторинга, может существенно варьироваться из-за различий в технических характеристиках устройств сбора данных и влияния внешних условий. В сочетании с индивидуальными особенностями пациентов эти факторы способны значительно влиять на точность прогноза [1-7].

В данной работе предложен подход к повышению качества прогнозов и выводов о функциональном состоянии опорно-двигательного аппарата пациентов после эндоскопической замены

суставов, за счёт совершенствования алгоритма предобработки данных, получаемых с помощью модуля компьютерного зрения. Предложенный подход позволяет формировать более точные и обоснованные прогнозы хода реабилитации, а также реализовать персонализированные решения в широком спектре практических задач [5, 7].

Особенности разработки медицинских систем поддержки принятия решений

Разработка систем в сфере здравоохранения требует особого подхода из-за необходимости учитывать сложные биомеханические и физиологические процессы, а также необходимости взаимодействия с уже существующими классическими медицинскими системами учета [1, 2]. Совместно с Федеральным государственным бюджетным учреждением «Федеральный центр травматологии, ортопедии и эндопротезирования» Министерства здравоохранения Российской Федерации (г. Смоленск), специализирующимся на оказании высокотехнологичной медицинской помощи пациентам с заболеваниями опорно-двигательного аппарата, ведётся разработка киберфизической системы управления реабилитацией пациентов после эндопротезирования суставов. Рассмотрим упрощённую модель взаимодействия элементов данной системы:

С помощью камеры мобильного устройства производится запись видео заданного движения пациента. Из полученного виде-




Рис. 1. Взаимодействие модулей системы

оряда, после предобработки данных, автоматически извлекаются ключевые признаки. Модуль компьютерного зрения собирает данные о позе, характеристиках движения и физических параметрах пациента. Анализируя эти данные, система формирует индивидуальную траекторию реабилитации.

Интеграция со специализированной медицинской информационной системой позволяет получить дополнительные данные об опорно-двигательном аппарате из истории болезни пациента, которые используются для корректировки прогноза системы, уточнения выводов и формирования обоснованных прогнозов реабилитации на послеоперационный период.

Технологии компьютерного зрения и машинного обучения помогают выявлять слабые места и отклонения в движениях пациентов. При анализе заданных упражнений интеллектуальная система распознаёт дисбаланс в работе мышц, отслеживает появление ограничений подвижности суставов и другие потенциальные риски, что позволяет своевременно скорректировать программу реабилитации, снижая риск повторной травматизации прооперированного сустава или нерационального распределения нагрузки на разных этапах послеоперационного периода.

Определение проблемы однородности качества данных

Следует отметить, что качество входных данных существенно влияет на точность итогового прогноза. Шум, недостаточная освещённость при съёмке, а также неоднородность качества изображений, получаемых с различных устройств — всё это существенно снижает достоверность информации, поступающей в систему. Таким образом, совершенствование модуля предобработки данных является актуальной задачей при разработке интеллектуальной СППР.

Для обучения и тестирования алгоритмов была сформирована репрезентативная база данных, включающая пациентов различного возраста и телосложения, что позволило учесть анатомическую вариативность. На первом этапе эти видеоматериалы

Counter	Input video	Output video	Opensim video	Opensim motion	Combined video
295	IMG_0630.MOV	IMG_0630.MOV	opensim.mp4	opensim.mot	combined.mp4
289	IMG_0675.MOV	IMG_0675.MOV	opensim.mp4	opensim.mot	combined.mp4
301	IMG_0682 (1).MOV	IMG_0682 (1).MOV	opensim.mp4	opensim.mot	combined.mp4
296	IMG_0632.MOV	IMG_0632.MOV	opensim.mp4	opensim.mot	combined.mp4
302	IMG_0686 (1).MOV	IMG_0686 (1).MOV	opensim.mp4	opensim.mot	combined.mp4
284	IMG_0687.MOV	IMG_0687.MOV	opensim.mp4	opensim.mot	combined.mp4
290	IMG_0688.MOV	IMG_0688.MOV	opensim.mp4	opensim.mot	combined.mp4
297	IMG_0636.MOV	IMG_0636.MOV	opensim.mp4	opensim.mot	combined.mp4
303	IMG_0689 (1).MOV	IMG_0689 (1).MOV	opensim.mp4	opensim.mot	combined.mp4
285	IMG_0684.MOV	IMG_0684.MOV	opensim.mp4	opensim.mot	combined.mp4
291	IMG_0685.MOV	IMG_0685.MOV	opensim.mp4	opensim.mot	combined.mp4
298	IMG_0638.MOV	IMG_0638.MOV	opensim.mp4	opensim.mot	combined.mp4
304	IMG_0692 (1).MOV	IMG_0692 (1).MOV	opensim.mp4	opensim.mot	combined.mp4
286	IMG_0680.MOV	IMG_0680.MOV	opensim.mp4	opensim.mot	combined.mp4
292	IMG_0681.MOV	IMG_0681.MOV	opensim.mp4	opensim.mot	combined.mp4
299	IMG_0640.MOV	IMG_0640.MOV	opensim.mp4	opensim.mot	combined.mp4
293	IMG_0678.MOV	IMG_0678.MOV	opensim.mp4	opensim.mot	combined.mp4
287	IMG_0675.MOV	IMG_0675.MOV	opensim.mp4	opensim.mot	combined.mp4
305	IMG_0682 (1).MOV	IMG_0682 (1).MOV	opensim.mp4	opensim.mot	combined.mp4
300	IMG_0642.MOV	IMG_0642.MOV	opensim.mp4	opensim.mot	combined.mp4
306	IMG_0679.MOV	IMG_0679.MOV	opensim.mp4	opensim.mot	combined.mp4
294	IMG_0677.MOV	IMG_0677.MOV	opensim.mp4	opensim.mot	combined.mp4

Рис. 2. Загруженные в систему видеоматериалы

были обработаны модулем компьютерного зрения, после чего результаты автоматической разметки были проверены и откорректированы специалистами вручную для обеспечения высокой точности.

В процессе эксплуатации системы и накопления видеоматериалов пациентов стационара были обнаружены ритмичные колебания измеряемых параметров у значительного числа наблюдаемых пациентов, не связанные с реабилитационным процессом. Анализ показал, что на эти данные влияют изменения внешней среды. Для повышения устойчивости системы было принято решение разработать отдельный модуль предобработки данных, включающий стабилизацию видеоряда, нормализацию данных, а также усовершенствованные подходы к отбору и обработке данных для обучения.

Задачей разработанного модуля предобработки является обеспечение стабильно высокого качества входных данных для анализа. Предварительная обработка включает очистку видеосигнала от шумов, нормализацию и преобразование данных для обучения моделей, что позволит в дальнейшем проводить анализ поступающих данных в режиме реального времени.

Модуль предобработки данных

Для оценки функционального состояния опорно-двигательного аппарата пациента в центре используется методика измерения угла сгибания сустава. Чтобы уменьшить влияние резких движений камеры и устранить визуальный шум, в модуле предобработки выполняется сглаживание траекторий ключевых точек. В разработанном модуле используется фильтр Калмана: он не требует больших вычислительных ресурсов по сравнению с нейросетевыми методами, эффективно сглаживает шум, корректирует траекторию движения объекта на основе наблюдений и нивелирует дрожание видео. В результате координаты опорных точек становятся более стабильными [4].

На следующем этапе проводится нормализация данных: координаты опорных точек приводятся к единой системе координат относительно антропометрических параметров пациента, что позволяет корректно оценивать прогресс пациентов с различными индивидуальными особенностями строения. В результате на вход модели поступает нормализованная поза пациента, полученная путём масштабирования и центрирования. Для повышения устойчивости работы нейросетей были применены методы увеличения данных: к исходным изображениям случайным образом вносились искажения. Такой подход существенно расширил обучающую выборку, одновременно позволив отсеять неинформативные и низкокачественные видеозаписи, что улучшило обобщающую способность алгоритмов. В итоге доля правильно определённых ключевых точек возросла до 96 %, точность распознавания составила 98,79 %, а устойчивость к различным условиям съёмки (различные ракурсы, бытовое освещение) повысилась на 17 %.




Рис. 3. Сравнение точности разметки: а) до применения фильтра Калмана; б) после применения фильтра Калмана

На основе данных, полученных от модуля компьютерного зрения, вычисляются количественные показатели: амплитуда движений в суставах, динамическая устойчивость, время реакции и скорость выполнения отдельных фаз движения. Для аппроксимации этих данных применено вейвлет-преобразование, что позволило выделить значимые особенности сигналов на разных масштабах и устранить оставшийся шум, сохранив локальные характеристики движений. Благодаря мультиразрешающему анализу удаётся точно восстановить структуру исследуемых процессов, а адаптивная фильтрация минимизирует потери информации при обработке [3].

Полученные показатели сравниваются с нормативными значениями дня реабилитации, что позволяет выявить скованность движений и на-




Рис. 4. Матрица Несоответствий




Рис. 5. Визуализация функциональных показателей

Patient 1207

Номер карты	Дата назначения	Инструктор
#№№/25	28/03/2025 11:32	Солдатенкова
Текст диагноза	Дата госпитализации	Дата выписки
Введите значение	27/04/2025 03:00	04/05/2025 05:05
Код диагноза	Сустав	
M17.1	Коленный	

Результаты Видео

Дата	Видео	Инструктор
	input.mp4	
	input.mp4	

Результаты Видео

Правило	Значение	Реф.	Значение	Реф.	Значение	Реф.	Значение	Реф.	Значение
Разгибание слева	6		4		7		7		
Разгибание справа	6		4		2		7		
Сгибание слева	75		80		126		70		
Сгибание справа	75		80		85		70		

Рис. 6. Выявленное отклонение функциональных показателей

Пациенты				
Все пациенты				
Архив				
Все пациенты (тест)				
#	Отделение	Палата	Дата назначения	Номер карты
6	2	301	2025-05-14	00-00
7	2	332	2025-05-13	07-12
8	2	326	2025-05-12	11-11

Рис. 7. Визуальное представление сигнальных статусов функционального состояния пациентов

рушения координации, свидетельствующие о необходимости дополнительных исследований:

Последующая кластеризации пациентов с помощью ANFIS-подобных нейронных сетей позволяет формировать для каждого кластера пациентов со схожими особенностями индивидуальный план восстановления и необходимый вид реабилитационной активности— групповые занятия, индивидуальные тренировки или упражнения на специализированных тренажёрах. Высокая прогностическая способность таких сетей даёт специалистам возможность своевременно корректировать индивидуальные траектории восстановления при прогнозируемом ухудшении состояния пациента, что повышает гибкость системы и позволяет учитывать дополнительные индивидуальные факторы, влияющие на восстановление каждого пациента.

Для реализации возможности более рационально использовать ресурсы медицинского учреждения, используется система сигнальных статусов:

Система сигнальных статусов позволяет выделять пациентов с отклонениями в ходе восстановления и формировать для них индивидуальные и групповые траектории реабилитации

Заключение

В работе рассмотрен подход к повышению точности прогнозирования функционального состояния опорно-двигательного аппарата пациентов после эндопротезирования суставов с по-

мощью интеллектуальной СППР. Применение описанного алгоритма предобработки исходных данных позволило как повысить точность распознавания, так и сохранить учёт индивидуальных особенностей пациентов. Предлагаемый алгоритм предобработки данных включает совокупность фильтров стабилизации видеоряда, вейвлет-преобразование и последующую кластеризацию результатов с помощью нейро-нечетких ANFIS-подобных сетей. Подключение данного модуля предобработки повысило точность определения ключевых точек опорно-двигательного аппарата на контрольном наборе до 96%, при этом среднее отклонение автоматически определённых координат от результатов ручной разметки не превышает $(2-3) \times 10^{-2}$ м.

В целом, взаимодействие модулей в разработанной СППР способствует выделению ключевых характеристик опорно-двигательного аппарата и повышению качества их анализа, что, в свою очередь, позволяет более точно выстраивать траектории реабилитации пациентов и эффективнее распределять ресурсы реабилитационных центров.

Библиография

1. **Arseniev, D. G., Borisov, V. V., Misnik, A. E., Gomzhina, E. A., Shalukhova, M. A.** (2024). Intelligent Synthesis of Individual Rehabilitation Plans for Patients after Joint Endoprosthesis Based on Computer Vision Technologies. In: *2024 7th International Conference on Information Technologies in Engineering Education (Inforino)*, Moscow, Russian Federation, pp. 1-5. [DOI: 10.1109/Inforino60363.2024.10552027].
2. **Borisov, V. V., Misnik, A. E., Velkov, A. A., Shalukhova, M. A.** (2023). Application of Computer Vision Technologies to Reduce Injuries in the Athletes' Training. [Текст] In: Kovalev, S., Kotenko, I., Sukhanov, A. (eds) *Proceedings of the Seventh International Scientific Conference "Intelligent Information Technologies for Industry" (ITI'23). IITI 2023. Lecture Notes in Networks and Systems*, vol 777. Springer, Cham. [DOI: 10.1007/978-3-031-43792-2_14].
3. **Chin, C. H., et al.** (2024). A review of the wavelet transform for durability and structural health monitoring in automotive applications. *Alexandria Engineering Journal*, vol. 99, pp. 204-216.

4. **Cuevas E. V., Zaldivar D., Rojas R.** Kalman filter for vision tracking. Technical report B 05-12. — Freie Universität Berlin, Institut für Informatik, 2005.

5. **Das, A., Shah, S., Adhikari, T. B., et al.** Computer vision syndrome, musculoskeletal, and stress-related problems among visual display terminal users in Nepal. *PLoS One*, (2022). [PMID: 35853006; PMCID: PMC9295968] [DOI: 10.1371/journal.pone.0268356].

6. **Devanne M., Wannous H., Berretti S., Pala P., Daoudi M., Del Bimbo A.** 3D human action recognition by shape analysis of motion trajectories on Riemannian manifold. *Transactions on Systems Man and Cybernetics [Текст]*, 2015, vol. 7, no. 45, pp. 1340-1352. [DOI: 10.1109/TCYB.2014.2350774].

7. **Wang, J., Qiu, K., Peng, H., Fu, J., Zhu, J.** AI coach: Deep human pose estimation and analysis for personalized athletic training assistance. In *Proceedings of the 27th ACM international conference on multimedia*, pp. 374-382 (2019). [DOI: 10.1145/3343031.3350910]

DATA CLUSTERING AND PRE-PROCESSING IN REHABILITATION MANAGEMENT

Dmitry G. Arsenyev^{1,a}, Anton E. Misnik^{2,b}, Maria A. Shalukhova^{2,c}

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia;
Belarusian-Russian University, Mogilev, Belarus

^aarsenjevasp@yandex.ru, ^banton@misnik.by, ^cshalukhova.m@yandex.ru

Abstract. This paper addresses ways to enhance rehabilitation management and to improve the accuracy of predictions and inferences generated by an intelligent decision-support system. We propose a methodology that refines the pre-processing pipeline for user data acquired through a computer-vision module. The study highlights the challenge posed by the variable quality of raw input data and introduces a combined strategy incorporating video-stream stabilization, data normalization, and wavelet transformation. Together, these techniques markedly increase the reliability of downstream analyses. Patient clustering is subsequently performed with ANFIS-like neuro-fuzzy networks, enabling highly accurate and personalized rehabilitation recommendations. The proposed approach raises the overall efficiency of rehabilitation programs, tailoring them to each patient's specific needs while further automating rehabilitation management processes.

Keywords. Clustering, computer vision, neural networks, data preprocessing, control systems, wavelet transformations, ANFIS-like neural networks.

* * *

ВОССТАНОВЛЕНИЕ СИГНАЛА ПО МАЛОМУ ЧИСЛУ НАБЛЮДЕНИЙ С НЕ УДОВЛЕТВОРЯЮЩИМИ ТРАДИЦИОННЫМ СТАТИСТИЧЕСКИМ ПРЕДПОЛОЖЕНИЯМ ПОМЕХАМИ

Лень Ирина Александровна¹, Чернов Андрей Олегович²
Санкт-Петербургский государственный университет,
Санкт-Петербург, Россия
¹i.a.len@spbu.ru, ²a.o.chernov@spbu.ru

Аннотация. В работе предлагается модель наблюдения для задачи восстановления разреженного сигнала по малому числу наблюдений. Предлагаемая модель учитывает помехи наблюдения, которые не удовлетворяют стандартным статистическим предположениям. Демонстрируются результаты моделирования, подтверждающие эффективность предложенной модели.

Ключевые слова: восстановление разреженного сигнала, опознание по сжатию, малое число наблюдений

Введение

Задачи по обработке сигналов возникают во многих областях человеческой деятельности. Одной из ключевых задач является задача реконструкции сигнала по наблюдениям.

Важнейшую роль в теории обработки сигналов занимает теорема Найквиста-Шеннона-Котельникова [1, 2, 3]. Она утверждает, что для гарантированного восстановления сигнала, частота его дискретизации должна не менее чем вдвое превышать максимальную частоту этого сигнала. Из-за этого, сохраненный дискретизированный сигнал требует больших объемов памяти для хранения. В результате приходится применять сжатие сигнала, которое, как правило, ведет к потере части информации.

Альтернативным подходом для хранения сжатого сигнала является опознание по сжатию (Compressive Sensing, CS) [4, 5]. Этот

подход позволяет восстановить разреженный сигнал по меньшему числу измерений, чем требует теорема Найквиста-Шеннона-Котельникова.

Важно отметить, что измерения сигналов всегда включают в себя помехи. Их источником могут быть как погрешности измеряющего прибора, так и внешние возмущения. В работах, посвященных обработке сигналов, часто делаются предположения о наличии у помех измерения полезных статистических свойств: случайности, независимости, одинакового распределения, центрированности, наличия второго конечного момента и других. Из-за этого могут возникать трудности при переносе теории на практику: в реальных задачах часто трудно (или невозможно) проверить выполнение этих предположений.

В этой статье предлагается модификация метода опознания по сжатию, предполагающая более общие помехи измерения, а именно неизвестные, но ограниченные (unknown-but-bounded) помехи. Условие о таких помехах значительно расширяет практические области применения метода, при этом не уменьшая его эффективность, что демонстрируют результаты экспериментов.

Постановка задачи

Для простоты изложения в работе будет рассматриваться вещественный одномерный сигнал конечной длины $f \in \mathbb{R}^n$. Сигнал регистрируется измерительным прибором, что математически представляется применением некоторого оператора $A: \mathbb{R}^n \rightarrow \mathbb{R}^m$, где m — размерность регистрируемых данных. Модель наблюдения будет выглядеть следующим образом:

$$y = Af + v, \quad (1)$$

где $v \in \mathbb{R}^m$ — помехи измерения от всех возможных источников неопределенностей.

В работе будут рассматриваться s -разреженные и s -сжимаемые сигналы.

Определение 1. Дискретный сигнал f называется s -разреженным, если он может быть представлен как:

$$f = \Psi x = \sum_{i=1}^n x_i \psi_i, \quad (2)$$

где $\Psi = (\psi_1, \dots, \psi_n) \in \mathbb{R}^{n \times n}$ – ортонормированный базис, в котором среди компонент вектора $x = (x_1, \dots, x_n)$ не более s ненулевых компонент.

Определение 2. Дискретный сигнал f называется s -сжимаемым, если он может быть представлен как (2), и среди компонент вектора x есть s достаточно больших компонент, а остальные – малы.

Модель наблюдений (1) для s -разреженного сигнала будет выглядеть следующим образом:

$$y_k = a_k, f + v_k, k = 1, \dots, m, \quad (3)$$

или

$$y = Af + v = A\Psi x + v = \Phi x + v, \quad (4)$$

где $y = (y_1, \dots, y_m)$ – наблюдения, $m \ll n$ – зарегистрированные наблюдения, $a_k \in \mathbb{R}^n$ – известные веса при проведении наблюдений, $\Phi = A\Psi \in \mathbb{R}^{m \times n}$ – матрица наблюдений.

Для решения задачи опознания по сжатию необходимо спроектировать универсальную матрицу A , не повреждающую информацию о любом s -разреженном или s -сжимаемом сигнале, при переходе от $f \in \mathbb{R}^n$ к $y \in \mathbb{R}^m$. Также необходим алгоритм реконструкции, восстанавливающий x по $m \sim s$ измерениям.

Основной результат

Матрица A должна быть подобрана так, чтобы было возможно восстановить сигнал f по значительно меньшему числу измерений. В силу построения, с матрицей A связана матрица Φ , которая для успешного восстановления сигнала должна обладать определенными свойствами.

Одним таким свойством является свойство ограниченной изометрии (Restricted Isometry Property, RIP) [6]: матрица $\Phi \in \mathbb{R}^{m \times n}$ обладает свойством $RIP(\delta, m)$ для любого s -сжимаемого вектора с параметрами $\delta(s) \in (0, 1)$, если:

$$\sqrt{1-\delta} \leq \frac{\Phi x_{l_2}}{x_{l_2}} \leq \sqrt{1+\delta}. \quad (5)$$

При прямом построении матрицы A необходимо проводить проверку выполнения свойства RIP для всех $\frac{n!}{s!(n-s)!}$ матриц Φ , соответствующих всем возможным положениям ненулевых компонент в s -разреженном сигнале.

Однако, как показано в [7], свойство RIP выполняется, если матрица A сформирована случайным образом.

Для восстановления сигнала f по имеющимся измерениям, матрицу наблюдений A и базису Ψ требуется алгоритм реконструкции. Для модели наблюдений (4) при отсутствующем шуме восстановление сигнала сводится к решению следующей выпуклой оптимизационной задачи:

$$\min x'_{l_1} : \Phi x' = y, \quad (6)$$

где матрица Φ удовлетворяет условию RIP [8].

Использование такой постановки задачи на практике затруднительно, поскольку в реальности измерения зашумлены, а сам сигнал не совсем разрежен. В таком случае следует рассматривать иную задачу выпуклой оптимизации [9]:

$$\min x'_{l_1} : \Phi x' - y_{l_2} \leq \epsilon. \quad (7)$$

Эта постановка реалистичнее, однако в ней точность восстановления ограничена уровнем шума. Для задач, в которых шумы не удовлетворяют такому предположению, требуется дальнейшая модификация.

Введем новую модель наблюдений:

$$\tilde{y} = (\Phi^T \Phi)' \Phi^T y = (\Phi^T \Phi)' \Phi^T \Phi x + (\Phi^T \Phi)' \Phi^T v, \quad (8)$$

где $[\cdot]'$ – оператор обращения матрицы. При такой модели наблюдений $E((\Phi^T \Phi)' \Phi^T v) = 0$, поэтому сигнал можно восстановить, решив следующую математическую задачу:

$$\min x'_i : E((\Phi^T \Phi)' \Phi^T \Phi x' - (\Phi^T \Phi)' \Phi^T \tilde{y}_i) \leq \epsilon. \quad (9)$$

Эксперимент

В эксперименте рассматривался сигнал, состоящий из взвешенной суммы 5 синусоид [10]:

$$f(t) = \sum_{i=0}^4 a_i \sin(2\pi + \omega_i t) + v, \quad (10)$$

где $t \in [0; 1)$, $\omega = \{80, 120, 200, 300, 450\}$ – активные частоты, $a = \{23.1, 20, 31.5, 23, 25\}$ – амплитуды. Восстановление сигнала проводилось по $m = 4s \log(n/s) \approx 153$ наблюдениям против 1000, требующихся по теореме Найквиста-Шеннона-Котельникова.

В первом сценарии при наблюдении использовался нормально распределенный шум. На рис. 1 представлено изображение оригинального, зашумленного и восстановленного сигналов в спектральном разложении. Благодаря спектральному представлению видно, совпадают ли пики, и, соответственно, можно понять, успешно ли был восстановлен сигнал.

Во втором сценарии использовался ступенчатый шум, не обладающий полезными статистическими свойствами. Его график представлен на рис. 2.

Спектральное представление оригинального, зашумленного и восстановленного сигналов представлено на рис. 3. На графике можно видеть, что зашумление создало «лишние» пики, которые, однако, были устранены при восстановлении.

Эксперименты демонстрируют, что предложенная модель наблюдений позволяет восстанавливать исходный сигнал по




Рис. 1. Спектральное представление сигналов (нормально распределенный шум)




Рис. 2. График ступенчатого шума

малому числу наблюдений, сделанных в условиях шумов, в том числе, шумов, не обладающих полезными статистическими свойствами.




Рис. 3. Спектральное представление сигналов (ступенчатый шум)

Заключение

В работе была рассмотрена задача опознания по сжатию. Классическая модель наблюдения, предполагающая наличие малых шумов с полезными статистическими свойствами, была модифицирована для работы в условиях неклассических помех. Были проведены эксперименты с моделированием, которые показали успешность работы предлагаемой модели как в условиях традиционных, так и нестандартных шумов.

Библиография

1. **Nyquist H.** Certain topics in telegraph transmission theory // Transactions of the American Institute of Electrical Engineers. — 1928. — Т. 47. — № 2. — С. 617–644.
2. **Shannon C. E.** Communication in the presence of noise // Proceedings of the IRE. — 1949. — Т. 37. — № 1. — С. 10–21.
3. **Котельников В. А.** О пропускной способности «эфира» и проволоки в электросвязи // Материалы к I Всесоюзному съезду по вопросам технической реконструкции дела связи и развития слаботочной промышленности. — 1933.

4. **Candes E., Romberg J., Tao T.** Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information // IEEE Transactions on Information Theory. — 2006. — Т. 52. — № 2. — С. 489–509.

5. **Donoho D.** Compressed sensing // IEEE Transactions on Information Theory. — 2006. — Т. 52. — № 4. — С. 1289–1306.

6. **Candes E. J.** The restricted isometry property and its implications for compressed sensing // Comptes Rendus Mathematique. — 2008. — Т. 346. — № 9–10. — С. 589–592.

7. **Candes E., Romberg J., Tao T.** Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information // IEEE Transactions on Information Theory. — 2006. — Т. 52. — № 2. — С. 489–509.

8. **Candes E. J., Romberg J. K., Tao T.** Stable signal recovery from incomplete and inaccurate measurements // Communications on Pure and Applied Mathematics: A Journal Issued by the Courant Institute of Mathematical Sciences. — 2006. — Т. 59. — № 8. — С. 1207–1223.

9. **Donoho D. L., Elad M., Temlyakov V. N.** Stable recovery of sparse overcomplete representations in the presence of noise // IEEE Transactions on Information Theory. — 2005. — Т. 52. — № 1. — С. 6–18.

10. **Граничин О. Н., Павленко Д. В.** Рандомизация получения данных и L1-оптимизация (опознание со сжатием) // Автоматика и телемеханика. — 2010. — Т. 11. — С. 3–28.

SIGNAL RECONSTRUCTION FROM LOW NUMBER OF OBSERVATIONS WITH DISTURBANCES NOT SATISFYING TRADITIONAL STATISTICAL ASSUMPTIONS

Irina A. Len¹, Andrey O. Chernov²

Saint Petersburg State University, St. Petersburg, Russia

¹i.a.len@spbu.ru, ²a.o.chernov@spbu.ru

Abstract. The paper proposes an observation model for the problem of sparse signal recovery from a limited number of observations. The proposed model considers measurement noise that does not satisfy standard statistical assumptions. Simulation results demonstrate the efficacy of the proposed model.

Keywords: sparse signal reconstruction, compressive sensing, low number of observations.

* * *

МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ЗАДАЧЕ АВТОМАТИЗАЦИИ ЭКСПЕРТИЗЫ НАУЧНЫХ ПРОЕКТОВ

Юркевичус Стасис Петрасович^{1,a}, Вражнов Денис Александрович^{2,b}

¹Республиканский исследовательский научно-консультационный центр,
Москва, Россия ,

²Институт оптики атмосферы им. В.Е. Зуева СО РАН, г. Томск, Россия
^ajursp@extech.ru, ^bvda@iao.ru

Аннотация. Данный обзор посвящен перспективам внедрения методов искусственного интеллекта (ИИ), в области автоматизации процедур оценки качества научно-исследовательских проектов (НИР). Приводится декомпозиция стандартной системы оценки НИР и оценивается потенциал внедрения методов ИИ в каждом сегменте системы. Также рассматривается автоматизация оценки проектов согласно шкале уровня готовности технологии. К наиболее перспективным областям был отнесен этап экспертизы заявки, за счет внедрения современных больших языковых моделей, способных облегчить работу экспертов по анализу текста на новизну, актуальность, плагиат.

Ключевые слова. Искусственный интеллект, машинное обучение, системы поддержки принятия решения, экспертиза научных проектов, системы оценки проектов.

Введение

В последнее время отмечается взрывная динамика развития как теоретических основ искусственного интеллекта (ИИ), так и областей его применения. Наиболее полно термин ИИ описывает совокупность методов и технологий в области компьютерных наук, позволяющих вычислительным машинам имитировать такие возможности человека, как рассуждать, принимать решения или решать проблемы [1, 2]. К современным областям применения ИИ относят компьютерное зрение и робототехнику [3], си-

стемы поддержки принятия решения (СППР) [4], в том числе ИИ агенты-консультанты (ChatGPT [5], DeepSeek [6]), позволяющие агрегировать, систематизировать и интерпретировать огромные массивы информации.

Важной особенностью создания ИИ систем является наличие размеченных экспертом данных либо эвристических правил, позволяющих реализовать процесс обучения модели на базе ИИ. Поэтому, согласно одной из классификаций ИИ выделяет модели, основанные на правилах или знаниях (экспертные системы) и модели на основе данных (машинное обучение) (рис. 1).

Экспертные системы широко применяются для решения формализованных задач с алгоритмизуемым решением. Примером таких систем являются СППР в медицине, основанные на протоколах и клинических рекомендациях [7]. Они не требуют значительных вычислительных мощностей, имеют небольшой набор оптимизируемых гиперпараметров.

Методы машинного обучения, включая глубокое обучение, позволяют строить модели данных со сложной структурой, обобщая известную информацию. Наиболее известными примерами являются большие языковые модели с миллиардами гиперпараметров и требующие использования дорогостоящих вычислительных кла-




Рис. 1. Классификация методов ИИ



Рис. 2. Задачи научной экспертизы НИР. Оранжевым цветом выделены потенциальные области применения ИИ. Серым цветом — недоступные в настоящее время для решения методами ИИ. Зеленым цветом — имеющие готовое автоматизированное решение

стеров для обучения моделей [8]. Следует отметить, что несмотря на стремительный рост сфер применения ИИ, решение творческих задач с применением методов ИИ зачастую неудовлетворительно. Это связано с ограниченностью выборки и необходимостью извлечения семантики для оценки качества генерируемых идей [9, 10].

Оценка качества научных проектов — трудоемкая задача, которая сейчас решается с привлечением экспертов. Соответственно, внедрение методов ИИ в данную область является актуальным. В данной работе исследуются области вышеуказанной задачи, в которых целесообразно и возможно внедрение методов ИИ.

Возможные направления применения методов искусственного интеллекта для экспертизы научных проектов

В задаче научной экспертизы можно выделить два основных направления — экспертиза заявок научных проектов и экспертиза научных отчетов (рис. 2). Экспертиза заявок научных проектов в большей части требует проверки соответствия формальным требованиям, например, количеству и качеству публикаций по теме

проекта (часть научного задела), наличие опыта руководства проектами и достаточностью материальной базы. В этой части оценки научного проекта широко распространена практика экспертизы научного отчета на основе опросников/анкет, с количественными оценками каждого критерия из списка. Итоговой оценкой отчета является взвешенная сумма баллов по критериям. Основной проблемой данного подхода является субъективность выбора соотношения баллов разделов опросника и, следовательно, невозможность существенно использовать экспертное мнение, основанное на опыте. Эту проблему гипотетически можно решить путем обучения алгоритма ИИ на выборке научных проектов, предварительно «размеченных» группой экспертов на набор классов, соответствующих «качеству» проекта, что позволит учесть более тонкие нюансы (признаки качества проекта) и повысить качество экспертизы новых проектов с применением методов ИИ.

К неформальным характеристикам проекта относится новизна, актуальность, соответствие методов и подходов решаемым задачам и т. п. Одной из ключевых проблем в этой области является то, что потенциальный ИИ агент на базе большой языковой модели должен обладать способностью осуществлять семантический анализ текста, то есть выделить смысл того, о чем авторы хотели сказать. ИИ агенты обучаются на известной информации и то, как они будут ее экстраполировать на неизвестную, остается открытым вопросом. Решение этой проблемы возможно с использованием интерпретируемых методов машинного обучения или проведения дополнительных исследований по надежности и адекватности заключений, полученных с использованием методов ИИ, работающих по принципу «черного ящика», к которым, в частности, относится большинство искусственных нейросетей. В развитие данной области, в работе [11] предлагается общий фреймворк для агентов ИИ основанный на принципах дивергентного и конвергентного мышления. В целом, на текущий момент, ни одна из современных больших языковых моделей не может на уровне человека понимать написанное. Тем не менее, уже сейчас возможно привлечение ИИ агентов к задачам выявления

плагиата, проверки данных статистического анализа и других манипуляций с данными [12].

Другой сложностью экспертизы научного проекта или научного отчета является оценка его новизны. В узком смысле новизна трактуется как непохожесть на существующие тексты. Классические методы для оценки схожести основаны на следующих метриках: косинусная (представляет собой косинус угла между двумя векторами в многомерном пространстве), tf-idf (Term Frequency-Inverse Document Frequency), учитывает частоту встречаемости слова в текстовом датасете), дивергенция Кульбака – Лейблера (статистическая мера измерения расстояния между вероятностными распределениями), ряд метрик для определения близости графов, а также метрики, используемые в методах кластеризации и классификации. Для обучения и валидации разрабатываемых моделей анализа текстов широко используется база TREC [13]. Этот датасет был разработан в рамках трехлетнего проекта по разработке методов анализа текстов, в частности оценки новизны и релевантности. Наилучшие достигнутые результаты – значение меры F1 (среднегармоническое между точностью и полнотой) в диапазоне 0,60–0,75, значения прецизионности и полноты 65–75 % [14]. В больших языковых моделях используются механизмы генерации семантических пространств на основе рекуррентных нейронных сетей [15], в частности, с архитектурами автокодировщик (например, Universal Sentence Encoder, USE) [16], долговременной и кратковременной памятью (Long Short Term Memory, LSTM) [17]. Для создания подобных моделей используются большие датасеты, такие как Wikipedia или Google News. Информация об аналогичных отечественных базах в открытом доступе отсутствует.

В работе [18] предлагается семантическая модель оценки новизны и актуальности на основе анализа групповых чатов, сохраненных во время «мозговых штурмов». Предлагаемая модель состоит из блока оценка релевантности, проработанности, новизны. Блок релевантности проводит удаление нерелевантных идей методами опорных векторов, вероятностными языковыми моделями [19]. Блок проработанности используется для исклю-

чения полностью сформулированных идей, используя информацию о длине и связности текста. Блок новизны оценивает релевантные и непроработанные идеи по количеству обсуждений на текущий момент и частоте встречаемости идеи в контекстном домене. Полученные результаты свидетельствуют о возможности применения больших языковых моделей для оценки новизны и актуальности проектов.

При оценке новизны идеи важно соблюдать баланс между ней и полезностью. На практике исследователи столкнулись с проблемой генерации галлюцинаций и идей в жестких рамках (меморизация, запоминание). Проблема галлюцинации моделей заключается в создании контента, далекого от реальности. При меморизации модель не может выйти за рамки существующих ограничений и генерирует идеи и с минимальными модификациями, не отвечающими критериям новизны.

Одним из текущих трендов развития тематик НИР в РФ стал акцент на прикладных технологических разработках. Для оценки зрелости технологических проектов применяется шкала уровней готовности технологии (УГТ) (англ. Technology Readiness Level, рис. 3) [20, 21].



Рис. 3. Пример шкалы УГТ для авиакосмической отрасли [20]




Рис. 4. Пример схемы применения модели машинного обучения для прогнозирования уровня технологической готовности [22]

Основным недостатком шкалы УГТ также является ее субъективность и неоднозначность выбора заявленным уровнем. Этим обусловлена необходимость разработки инструментов независимой оценки уровня УГТ. Пилотные работы в данном направлении показали перспективность использования библиометрических индикаторов в качестве предикторов уровня готовности технологии [22, 23]. К последним авторы отнесли наличие венчурного капитала, рыночной оценки, лицензированных технологий, исследовательских проектов, клинических испытаний, научных публикаций, патентов, новостей и упоминаний в СМИ. Более того, учитывая комплексный характер показателей и нелинейный характер зависимостей между предикторами и целевой переменной, было предложено использовать модели машинного обучения для предсказания уровня УГТ (рис. 4).

Заметим, что вместо предсказания уровня УГТ можно использовать методы машинного обучения для предсказания положения разрабатываемой технологии на кривой Хайпа Гартнера. Критерии соответствия проблемы приоритетным направлениям научных исследований, квалификация и опыт научного коллектива, использование ожидаемых результатов НИР на практике выражаются количественно, и их оценка не требует экспертизы человека-эксперта.

Заключение

В данной работе были рассмотрены основные этапы экспертизы научных проектов и научных отчетов. Проведенная декомпозиция на подзадачи и анализ литературы показала, что наиболее эффективной является автоматизация рутинных процедур на этапе экспертизы заявки. Это обусловлено большой долей субъективности оценок отчетного этапа и внедрения опросников с количественными показателями выполнения НИР, что не требует применения методов на базе ИИ. На этапе экспертизы заявок внедрение современных больших языковых моделей может существенно упростить работу экспертов в области анализа текста на новизну, актуальность, плагиат.

Библиография

1. Helm J. M. et al. Machine learning and artificial intelligence: definitions, applications, and future directions //Current reviews in musculoskeletal medicine. — 2020. — Т. 13. — С. 69–76.
2. Sheikh H., Prins C., Schrijvers E. Artificial intelligence: definition and background //Mission AI: The new system technology. — Cham : Springer International Publishing, 2023. — С. 15–41.
3. Murphy R. R. Introduction to AI robotics. — MIT press, 2019.
4. Gupta S. et al. Artificial intelligence for decision support systems in the field of operations research: review and future scope of research //Annals of Operations Research. — 2022. — Т. 308. — № 1. — С. 215–274.
5. Kalla D. et al. Study and analysis of chat GPT and its impact on different fields of study //International journal of innovative science and research technology. — 2023. — Т. 8. — №. 3.
6. Wu Z. et al. Deepseek-v12: Mixture-of-experts vision-language models for advanced multimodal understanding //arXiv preprint arXiv:2412.10302. — 2024.
7. Толмачев И. В. и др. Возможности и ограничения использования программных информационных устройств с искусственным интеллектом для диагностики и лечения заболеваний.
8. Minaee S. et al. Large language models: A survey //arXiv preprint arXiv:2402.06196. — 2024.
9. Sarathy V., Scheutz M. Macgyver problems: Ai challenges for testing resourcefulness and creativity //Advances in Cognitive Systems. — 2018. — Т. 6. — С. 31–44.

10. **Runco M. A.** AI can only produce artificial creativity //Journal of Creativity. — 2023. — Т. 33. — № 3. — С. 100063.

11. **Mukherjee A., Chang H.** The creative frontier of generative ai: Managing the novelty-usefulness tradeoff //arXiv preprint arXiv:2306.03601. — 2023.

12. **Molnár G., József C.** AI Based Plagiarism Checking: Ease of use and applicable system for teachers to find similarities in students' assessments //2022 IEEE 5th International Conference and Workshop Óbuda on Electrical and Power Engineering (CANDO-EPE). — IEEE, 2022. — С. 000187–000192.

13. **Soboroff I., Harman D.** Novelty detection: the trec experience // Proceedings of human language technology conference and conference on empirical methods in natural language processing. — 2005. — С. 105–112.

14. **Doboli S.** et al. A cognitive inspired method for assessing novelty of short-text ideas //2020 International Joint Conference on Neural Networks (IJCNN). — IEEE, 2020. — С. 1–8.

15. **K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio,** “Learning phrase representations using RNN encoder–decoder for statistical machine translation,” in Proc. of 2014 Conf. on Empirical Methods in Natural Language Processing (EMNLP), Doha, Qatar, Oct. 2014, pp. 1724–1734.

16. **Cer D.** et al. Universal sentence encoder for English //Proceedings of the 2018 conference on empirical methods in natural language processing: system demonstrations. — 2018. — С. 169–174.

17. **Tai K. S., Socher R., Manning C. D.** Improved semantic representations from tree-structured long short-term memory networks //arXiv preprint arXiv:1503.00075. — 2015.

18. **Fisher D.** et al. A real-time semantic model for relevance and novelty detection from group messages //2022 International Joint Conference on Neural Networks (IJCNN). — IEEE, 2022. — С. 01–08.

19. **Zhai C. X., Lafferty J.** Two-stage language models for information retrieval //Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval. — 2002. — С. 49–56.

20. **Анохов И. В.** Шкала уровня технологической готовности УГТ и перспективы ее модификации //Стратегии бизнеса. — 2022. — Т. 10. — № 11. — С. 289–294.

21. **Hirshorn S.** NASA System Engineering Handbook SP-2016-6105 Rev2 //Washington, DC. — 2016.

22. **Faidi S.** Assessing Bibliometrics for the Automation of Technology Readiness Level Assessments. — University of Toronto (Canada), 2021.

23. **Dastoor J.** et al. A Bibliometric Approach to Characterizing Technology Readiness Levels Using Machine Learning //AIAA SCITECH 2023 Forum. — 2023. — С. 2686.

METHODS OF ARTIFICIAL INTELLIGENCE IN THE PROBLEM OF AUTOMATION OF EXPERTISE OF SCIENTIFIC PROJECTS

Stasis P. Yurkevichyus^{1,a}, Denis A. Vrazhnov^{2,b}

¹SRI FRCEC, Moscow, Russia,

²V.E. Zuev Institute of Atmospheric Optics Russian Academy of Sciences, Siberian Branch, Tomsk, Russia

^ajursp@extech.ru, ^bvda@iao.ru

Abstract. This review is devoted to the prospects for the introduction of artificial intelligence (AI) methods, in the field of automation of procedures for quality assessment of research projects (R&D). A decomposition of the standard system of R&D evaluation is given and the potential of AI methods implementation in each segment of the system is evaluated. The automation of project evaluation according to the technology readiness level scale is also considered. The most promising areas include the stage of the application examination, due to the introduction of modern large language models that can facilitate the work of experts in analyzing the text for novelty, relevance, and plagiarism.

Keywords: artificial intelligence, machine learning, decision support systems, expertise of scientific projects, project evaluation systems.

* * *

УДК 004.896

doi:10.18720/SPBPU/2/id25-545

МОДЕЛИ САМООРГАНИЗАЦИИ ДЛЯ ПРОМЫШЛЕННЫХ ИНФОРМАЦИОННЫХ СИСТЕМ

Куприянов Михаил Степанович¹, Кочетков Андрей Валерьевич²

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ», Санкт-Петербург Россия

¹mskupriyanov@mail.ru, ²gaidn@yandex.ru

Аннотация. В статье анализируются основные задачи, возникающие при управлении производственными процессами промышленных предприятий: распределение ресурсов и планирование их использования; комплексная оценка эффективности и экономической прибыльности их

функционирования; прогнозирование и оптимизация ключевых параметров. Для решения вышеуказанных задач в условиях современной постановки задачи предлагается использовать набор моделей, построенных на принципах самоорганизации. В частности, для решения задачи прогнозирования и оптимизации функционирования системы, предлагается использовать новый подход, в основе которого лежит индуктивный метод самоорганизации моделей.

Ключевые слова. Самоорганизующиеся системы; модели самоорганизации; рыночная модель самоорганизации, индуктивный метод.

Введение

Информационные системы современных промышленных предприятий и их сетей должны эффективно решать следующие основные классы задач: планирование использования и распределение ресурсов; оценка различных комплексных, в том числе экономических, показателей эффективности функционирования предприятия; прогнозирование динамики изменения таких показателей; выработка рекомендаций по управлению для целей оптимизации и повышения эффективности и прибыльности.

В условиях растущей сложности современного мира, постоянной динамики спроса и предложения, частыми появлениями непредсказуемых событий, глобализации рынка рабочей силы, взаимозависимостями принимаемых решений, сетевой организации современного бизнеса, всё более остро встаёт проблема создания промышленных информационных систем (ПИС) реального времени, способных быстро адаптироваться к внутренним и внешним изменениям. Становится очевидным, что на смену централизованным, монолитным, детерминированным системам управления должны прийти системы управления, построенные на принципах самоорганизации. Система должна сама (или при минимальном участии человека в контуре) изменить параметры, функции и/или свою структуру в ответ на изменившуюся внешнюю и/или внутреннюю обстановку.

В качестве технологической базы для практической реализации самоорганизующихся систем широкое распространение получи-

ли мультиагентные технологии, которые позволяют представить процесс решения задачи в виде взаимодействия множества подзадач (называемых агентами), в ходе которого удается достигать компромиссного решения, удовлетворяющего всех участников, вовлечённых в процесс решения общей комплексной задачи. При этом сам мультиагентный подход рассматривается как парадигма вычислений на основе взаимодействий, а всё множество взаимодействий отдельных частей системы на локальном микроуровне приводит, в итоге, к решению общей задачи на макроуровне, как эмерджентный эффект таких взаимодействий.

Далее, в данной статье, рассматривается применение нескольких известных моделей самоорганизации для решения вышеуказанных задач в ПИС.

Модели самоорганизации для планирования и распределения ресурсов

Классические задачи планирования ресурсов обычно формулируются как пакетный запрос, в котором все заказы/запросы и доступные для их выполнения ресурсы известны заранее, а процесс поиска оптимального расписания использования ресурсов осуществляется комбинаторным перебором всех вариантов. По такому принципу работают методы линейного и динамического программирования, «жадные» методы локального поиска, различные биовдохновлённые методы, наподобие муравьиных алгоритмов, алгоритмов оптимизации роем частиц и др. Модификации этих методов, построенные на различного рода эвристиках, в ряде случаев позволяют заметно сократить пространство комбинаторного поиска, но являются совершенно не эффективными в современной постановке задачи.

Модель сети потребностей и возможностей. Формальная постановка задачи планирования и распределения ресурсов включает в себя: множество ресурсов $S = \{S_1, S_2, \dots, S_n\}$ и множество заказов/запросов $D = \{D_1, D_2, \dots, D_m\}$. Согласно концепции сети потребностей и возможностей, каждому ресурсу в модели поставлен в соответствие

программный агент возможности (Supply Agent, SA), а каждому заказу, заявке — программный агент потребности (Demand Agent, DA). Каждый из агентов имеет свои собственные локальные цели, критерии и ограничения. В качестве критериев для агентов потребностей DA_i могут быть срок, стоимость, риск, приоритет, быстрота обслуживания, тип оборудования и т. д., для агентов возможностей SA_i — отсутствие простоев, перегрузок, максимизация дохода и др. Полагается, что все агенты в системе являются «самоинтересованными», в том смысле, что стремятся максимизировать свою собственную удовлетворенность по каждому из критериев [1, 2].

Пусть удовлетворенность каждого агента потребности DA_i оценивается по k различным критериям: $U_j^i = \{U_1^i, U_2^i, \dots, U_k^i\}$. Для оценки удовлетворенности агента по критерию U_j^i с известным идеальным значением критерия может быть предложена нормализованная функция удовлетворенности вида $U_j^i = f_j(x - x_{id})$, где x — текущее, а x_{id} — идеальное значение рассматриваемого критерия. Обычно в качестве функции f используют некоторую колоколообразную функцию, имеющую максимум в точке идеального значения x_{id} . Возможный вариант такой функции приведен на рис. 1а, а типичная зависимость удовлетворенности от времени — на рис. 1б. Для реализации рыночного механизма самоорганизации, описываемого далее, действия агентов зависят также и от функции штрафов/бонусов в системе виртуальных денег. Изначально полагается, что агенты располагают определённой суммой виртуальных денег, а в дальнейшем их бюджет меняется в зависимости от их удовлетворенности. Пример вида функции штраф/бонусов изображен на рис. 1в.

Итоговая удовлетворенность каждого агента потребности DA_i может быть найдена как взвешенная сумма его удовлетворённости по каждому из критериев, весовые коэффициенты при этом нормализованы и отражают текущую степень важности каждого критерия:

$$U^i = \sum_{j=1}^k \alpha_j U_j^i, \quad \sum_{j=1}^k \alpha_j = 1, \quad i \in [1, n] \quad (1)$$




Рис. 1. Пример получения нормированной функции удовлетворенности (а), функции удовлетворенности (б) и функции бонуса/штрафов (в)

Задача поиска наилучшего распределения по ресурсам для всего множества агентов потребностей формулируется как задача поиска максимума суммарной функции удовлетворенностей всех агентов потребностей:

$$\sum_{i=1}^n U^i \rightarrow \max \quad (2)$$

Аналогично, для агентов возможностей, задача поиска наилучшего использования своих мощностей формулируется как оптимизационная задача поиска максимума суммарной функции удовлетворенностей всех агентов возможностей:

$$\sum_{i=1}^m U^{res-i} \rightarrow \max \quad (3),$$

где m — число агентов возможностей (ресурсов) в системе, а верхний индекс res указывает на то, что данный критерий относится к агентам возможностей.

Содержательно, данная модель может быть представлена в виде аукциона, в котором агенты возможностей и потребности ведут переговоры между собой в поисках взаимного соответствия для максимизации своих показателей удовлетворенности. В случае успеха, пара агентов заключают «делку» (такая операция называется мэтчином) — ресурс резервирует у себя слот времени, запрашиваемый потребностью. Сделки имеют свои параметры, в том числе выражаемые в виртуальных деньгах.

Такой рыночный механизм, заимствованный из экономической теории, предполагает постоянный поиск агентами обоих типов более лучших размещений, что ведет к проактивному улучшению показателей удовлетворенности агентов и всей системы в целом. Сеть является динамической, в ней могут появляться новые заявки, уходить обслуженные, добавляться новые ресурсы и ломаться текущие, сделки могут разрываться (рис. 2). Использование виртуальных денег в системе позволяет агентам идти на взаимные уступки, а в последствие искать более выгодные решения. Необходимо также отметить, что слишком частое изменение расписания использования ресурсов — называемое степенью нервозности системы — является нежелательным эффектом применения рыночного механизма, и должно быть ограничено путем введения несложных эвристических примитивов.

Полученный самоорганизующийся план использования и загрузки ресурсов далее может быть представлен пользователю в графическом представлении бизнес-процессов, например, с помощью диаграмм Ганта, для дальнейшей доработки, согласования и утверждения.




Рис. 2. Формирование сети потребностей и возможностей на виртуальном рынке агентов

Самоорганизующаяся модель В2В-сети. Дальнейшим развитием рыночной модели самоорганизации ПИС является распределенная координация расписаний бизнес-процессов в В2В-сети. В2В-сетями называется вид экономического и информационного взаимодействия множества предприятий, имеющий целью координацию планирования и исполнения распределенных бизнес-процессов в интересах самого бизнеса [3].

Топология В2В-сети представляет собой одноранговую (peer-to-peer) сеть, в узлах которой находятся отдельные предприятия или компании, которые совместно участвуют в производстве некоторого продукта, заказы на производство которого могут поступать в любой узел системы в режиме реального времени. Задачей ПИС В2В-сети является выработка согласованного расписания использования ресурсов отдельных предприятий, составляющих сеть, и последующий контроль его выполнения.

Необходимо отметить, что для реализации процессов координации в В2В-сети на предварительном этапе, на каждом узле должна быть развернута программно-коммуникационная платформа, позволяющая работать предприятиям в рамках единого информационно-семантического пространства. Такая платформа должна поддерживать открытость системы, интероперабельность узлов, единую схему адресации. Будем полагать, что такая платформа уже создана.

В формальную модель В2В-вводятся два типа агентов: агент узла DepA (Department Agent) и агент заказа OA (Order Agent), каждый из которых является агентом метауровня. Агент узла ответственен за составление локального расписания использования своих ресурсов, а также за распределенную межузловую координацию расписаний выполнения заказов в сети. Агент заказа, в выполнение которого вовлечено множество узлов сети, ответственен за соблюдение всех технологических процессов при производстве конечного продукта, а также временные рамки его выполнения.

Выполнение заказа в такой сети можно разбить на три этапа:

1. Каждый заказ разбивается на частично-упорядоченное по времени множество подзаказов, каждый из которых в силу тех или иных причин, должен быть выполнен отдельным узлом сети

$A = \{a_1, a_2, \dots, a_p\}$. Автоматизация данного этапа в литературе пока не предложена.

2. Агент узла $DerA_i$, в который поступил новый заказ, проводит виртуальные торги, реализуя рыночную модель самоорганизации в виде аукциона на множестве своих соседей по сети. На виртуальные торги последовательно выставляются все подзаказы из множества $\{a_1, a_2, \dots, a_p\}$. Получая ответы от агентов соседних узлов $DerA_j$ строит распределенное расписание выполнения заказа в целом, и информирует об этом агентов выигравших узлов.

3. Алгоритм распределенной координации вызывается всякий раз, когда происходит так называемое смежное событие. Смежное событие связано с окончанием выполнения своей части работы (подзаказа) одним узлом сети и продолжением его выполнения (следующим подзаказом) другим узлом. Координация осуществляется путем взаимодействия соответствующих двух агентов узлов B2B-сети.

Индуктивный метод самоорганизации моделей

Принципиально другие модели самоорганизации могут быть использованы при решении задачи оценки и прогнозирования ключевых показателей функционирования, например, экономических, в ПИС. Имитационная модель, позволяющая решить указанные задачи, должна отражать всю сложность рассматриваемой ПИС, и выражаться, в конечном итоге, некоторой целевой функцией системы Y , зависящей как от управляемых параметров, так и от реализуемых системой функций и её структуры.

Для построения целевой функции системы предлагается использовать индуктивный метод самоорганизации моделей, более известный как метод группового учета аргументов (МГУА) [4]. Метод развивается с конца 60х годов прошлого века и является в настоящее время достойной альтернативой применению нейронных сетей по целому ряду показателей.

МГУА позволяет найти модель оптимальной сложности из заданного класса моделей, чтобы описать имеющийся набор данных

$$\begin{array}{lll} Y_0 = a_0 & & \\ Y_1 = a_0 + a_1x_1 & Y_1 = a_0 + a_2x_2 & \dots\dots\dots Y_1 = a_0 + a_{100}x_{100} \\ Y_2 = a_0 + a_1x_1 + a_2x_2 & Y_2 = a_0 + a_1x_1 + a_3x_3 & \dots\dots\dots Y_2 = a_0 + a_{99}x_{99} + a_{100}x_{100} \\ & & \dots\dots\dots \end{array}$$

Рис. 3. Пример формирования усложняющихся моделей для алгоритмов МГУА

наблюдения. Для этого используется многорядное постепенное усложнение модели, каждый ряд связан с одним уровнем сложности модели. Алгоритмы отличаются условиями формирования и отбора переменных при переходе от одного ряда к другому. Пример постепенного усложнения моделей при переходе от ряда к ряду, для линейных функций многих переменных, показан на рис. 3.

Для оценки качества текущей модели используется значение внешнего по отношению к обучающей выборке критерия, рассчитываемого на проверочной выборке данных, в качестве которого используется критерий регулярности или критерий несмещенности модели. Авторы метода теоретически доказали существование минимума значения этих критериев при усложняющемся наращивании количества рядов моделей. Обнаружение минимума критерия при переходе к следующему ряду свидетельствует о нахождении модели оптимальной сложности, в качестве которой выбирается «лучшая» модель текущего ряда.

Отметим, что использование индуктивного метода самоорганизации позволяет при построении модели оптимальной сложности, автоматически отбросить все несущественные переменные, которые изначально рассматривались как переменные состояния модели ПИС.

Модели параметрической, функциональной и структурной самоорганизации

Будем рассматривать распределенную ПИС как набор составляющих её элементов и связей между ними. В разработанной модели каждому элементу поставлен в соответствие программный

агент, который моделирует поведение элемента. Иерархическая структура такой ПИС может быть представлена в виде дерева. Узлы дерева делятся на два типа: узлы, соответствующие листам дерева – им поставлен в соответствие программный базовый агент (БА); остальным узлам поставлен в соответствие программный агент-посредник (АП). Отличие между базовым и агентом-посредником заключается в том, что базовый агент моделирует выполнение агентом той или иной функции, в то время как агент-посредник осуществляет функции управления, передачи данных между уровнями, планирования дальнейших действий подчинённых ему базовых агентов. В корне такого дерева, который может быть виртуальным, индуктивным методом самоорганизации моделей формируется целевая функция ПИС и осуществляется контроль её значений. Для поддержания необходимого уровня значений целевой функции используются модели и методы параметрической, функциональной и структурной самоорганизации. Подробное описание этих моделей и методов приведено в более ранних работах авторов, например, [5].

Заключение

В работе были выделены основные задачи, возникающие при управлении производственными процессами промышленных предприятий. Для каждой задачи была приведена её формальная постановка и предложена самоорганизующаяся модель для её решения. Дальнейшие исследования будут направлены на создание программных прототипов моделей ПИС, позволяющих провести эксперименты с предложенными моделями в конкретных предметных областях.

Библиография

1. Модель динамики агентов потребностей и возможностей / И. В. Майоров, П. О. Скобелев // Проблемы управления и моделирования в сложных системах: Труды XVII Международной конференции, Самара, 22–25

июня 2015 года / Под ред.: Е.А. Федосова, Н.А. Кузнецова, В.А. Виттиха. – Самара: Самарский научный центр РАН, 2015. – С. 79–87.

2. Мультиагентные технологии и самоорганизация сетей связанных расписаний для управления ресурсами в реальном времени / Скобелев П. О. Майоров И. В. // Морские информационно-управляющие системы. – 2015. – № 1(7). – С. 24–39.

3. Многоагентная самоорганизация в В2В сетях / В. И. Городецкий // XII всероссийское совещание по проблемам управления ВСПУ-2014, Москва, 16–19 июля 2014 года / Институт проблем управления им. В. А. Трапезникова РАН. – Москва: Институт проблем управления им. В. А. Трапезникова РАН, 2014. – С. 8954–8966.

4. А. Г. Ивахненко. Индуктивный метод самоорганизации моделей сложных систем. – Киев: «Наук. думка», 1982.

5. Управление сложными техническими системами на основе методов самоорганизации / М. С. Куприянов, А. В. Кочетков // Международная конференция по мягким вычислениям и измерениям. – 2015. – Т. 1. – С. 281–284.

SELF-ORGANIZATION METHODS FOR INDUSTRIAL INFORMATION SYSTEMS

Mikhail S. Kupriyanov¹, Andrey V. Kochetkov²

Saint Petersburg Electrotechnical University «LETI», Saint Petersburg, Russia

¹mskupriyanov@mail.ru, ²gaidn@yandex.ru

Abstract. The article analyzes the main tasks that arise in the management of industrial enterprises' production processes: allocation of resources and planning their usage; comprehensive assessment of the effectiveness and economic profitability of their operation; key parameters forecasting and optimization. To solve the above tasks in the context of modern problem formulation, proposed to use a set of models based on the principles of self-organization. In particular, to solve the problem of forecasting and optimizing the functioning of the system, proposed to use a new approach based on the inductive method of self-organization of models. This approach obtains a model of optimal complexity, used later in algorithms of parametric, functional and structural self-organization.

Keywords. Self-organizing systems, models of self-organization, market model of self-organization, inductive method.

* * *

ПОДГОТОВКА ИНЖЕНЕРНО-ТЕХНИЧЕСКИХ КАДРОВ ПО ЗАКАЗУ ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ НА ПРИМЕРЕ СОВМЕСТНОГО ЦИФРОВОГО ХАКАТОНА

Батц Евгений Александрович^{1,а}, Крайнюченко Ярослав Вадимович^{2,б},
Машьянов Константин Кириллович^{3,в}

¹АО «Кольская горно-металлургическая компания»,
г. Мончегорск, Россия,

²Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

^аBattsEA@kolagmk.ru, ^бKraynyuchenkoyav@kolagmk.ru,
^вmashyanov_kk@spbstu.ru

Аннотация. Статья описывает опыт подготовки инженерно-технических кадров на примере совместного цифрового хакатона, организованного ФГАОУ ВО «СПбПУ» и АО «Кольская ГМК». Мероприятие включало решение прикладных задач промышленного ИИ на основе обезличенных данных гидрометаллургического производства, что позволило студентам получить реальные компетенции. Формат показал эффективность интеграции образования и промышленности, а также развитие технических и коммуникационных компетенций у студентов.

Ключевые слова. Инженерное образование, цифровой хакатон, промышленный ИИ, подготовка кадров, машинное обучение, СПбПУ, Кольская ГМК, проектное обучение, взаимодействие вузов и предприятий.

Введение

В современном мире цифровизация и технологическая трансформация промышленности требуют пересмотра подходов к подготовке инженерно-технических кадров. Образовательные учреждения всё чаще сталкиваются с необходимостью адаптировать учебные программы под запросы конкретных предприятий. Эффективное взаимодействие с индустриальными партнёрами

становится критическим фактором подготовки востребованных специалистов [1].

Одной из действенных форм такого взаимодействия является проведение совместных хакатонов — интенсивных командных соревнований, в которых студенты решают прикладные задачи, поставленные промышленными заказчиками [2]. Это позволяет не только развивать технические компетенции, но и формировать навыки командной работы, управления проектами и коммуникации с реальными заказчиками.

В феврале 2025 года на базе ФГАОУ ВО «СПбПУ» и АО «Кольская ГМК» был проведён первый совместный цифровой хакатон с акцентом на промышленный ИИ [3]. Участие в хакатоне дало студентам возможность погрузиться в практические кейсы и взаимодействовать с экспертами вуза и предприятия.

Постановка задачи

Актуальность проблемы. Современное инженерное образование отстаёт от потребностей индустрии в части цифровых навыков, гибкости решений и ориентации на конкретные производственные кейсы. Необходим переход от абстрактных заданий к решению реальных задач предприятий.

Цель исследования. Целью настоящей статьи является демонстрация механизма подготовки инженерных кадров по заказу предприятий на примере цифрового хакатона, организованного совместно с промышленным партнёром.

Методология и описание кейса

Целями хакатона стали: выработка вариативности решений задач КГМК в области ML, а также апробация различных подходов к моделированию, выявление лучших студентов и аспирантов.

Участникам была представлена задача, в рамках которой искали зависимости в обезличенном датасете гидрометаллургического производства с применением, как классических методов машин-

ного обучения, так и нейросетевых [4]. Таким образом задача была состояла из следующих этапов:

- Проанализировать датасет: выявить пропуски, выбросы и аномалии.
- Очистить данные: удалить пропуски, выбросы и аномальные значения.
- Исследовать корреляции: построить и визуализировать матрицу корреляций.
- Построить линейную регрессию: выбрать метрики, интерпретировать результаты, провести тюнинг.
- Построить модель градиентного бустинга (CatBoost, XGBoost и др.): выбрать метрики, интерпретировать результаты, провести тюнинг.
- Сравнить модели и метрики: оценить качество и применимость, выбрать лучшую модель.
- Рекомендовать модель для промышленного применения и обосновать выбор.
- Попробовать модель на основе нейронных сетей (например, KAN).

Таким образом хакатон стал примером Problem-Based Learning (PBL), где студенты учатся на основе реальных производственных задач [5].

По итогам заочного решения задачи была проведена очная защита со строгим регламентом — 10 минут на презентацию участниками и 5 минут — на вопросы от членов жюри, которые были представлены с обеих организаций.

Результаты и перспективы

На финальную защиту вышли пять сильнейших команд, прошедших предварительный отбор. Хакатон носил международный характер: участие приняли студенты из семи разных стран, что подчеркнуло как глобальный интерес к теме промышленного ИИ, так и открытость формата для межкультурного взаимодействия.

Уровень подготовки команд был высоко оценён экспертным жюри, в состав которого вошли представители промышленного заказчика, научно-педагогического сообщества и практикующие инженеры. Участники продемонстрировали отличные навыки работы с данными, понимание специфики производственных процессов и умение находить нестандартные инженерные решения.

Сам формат защиты можно охарактеризовать как «бизнес-питч под давлением времени» — каждая команда имела всего 10 минут для представления своей разработки. За это время необходимо было не только изложить техническую суть решения, но и убедительно аргументировать его применимость, экономическую целесообразность и потенциал для внедрения. Таким образом, защита стала настоящей проверкой на прочность как технических, так и презентационных навыков студентов.

Хакатон показал, что его участники готовы не просто выполнять учебные задания, а работать на стыке инженерии, цифровых технологий и бизнес-аналитики. Для многих это мероприятие стало не только возможностью применить полученные знания, но и первым серьёзным шагом в профессиональную карьеру. По итогам мероприятия несколько участников были приглашены на стажировки в подразделения промышленного партнёра.

Формат хакатона позволяет вузам синхронизировать образовательные программы с индустриальными потребностями. Студенты, работая над реальными задачами, развивают гибкие навыки, умение быстро адаптироваться и учиться, что особенно ценно в условиях быстро меняющегося технологического ландшафта.

Заключение

В работе был изучен подход к подготовке инженерно-технических кадров по заказу промышленных предприятий на примере совместного Цифрового хакатона.

Проведённый цифровой хакатон, организованный СПбПУ совместно с «Кольской ГМК», стал успешным примером прак-

тико-ориентированной подготовки инженерно-технических кадров в условиях цифровизации промышленности. Участники продемонстрировали высокий уровень владения методами анализа данных и машинного обучения, а также способность применять полученные знания для решения реальных производственных задач.

Мероприятие подтвердило эффективность формата хакатона как инструмента интеграции образования и промышленности. Работа студентов в условиях ограниченного времени, публичной защиты и жёсткой конкуренции способствовала формированию не только профессиональных, но и универсальных навыков: командного взаимодействия, презентации технических решений, понимания бизнес-логики и экономической обоснованности.

Хакатон показал, что современные студенты готовы к работе на стыке инженерии, цифровых технологий и бизнес-аналитики. Его результаты продемонстрировали, что сотрудничество между университетом и промышленным партнёром способно не только повысить качество образования, но и сформировать кадровый резерв для высокотехнологичных предприятий.

Полученный опыт может быть масштабирован и использован в других вузах и отраслях в рамках программ модернизации инженерного образования и развития промышленной кооперации.

Библиография

1. Adapting Engineering Education to Industrie 4.0 Vision, 2017. [Онлайн доступ] / https://arxiv.org/abs/1710.08806?utm_source=chatgpt.com.
2. Embracing Experiential Learning: Hackathons as an Educational Strategy for Shaping Soft Skills in Software Engineering, 2025. [Онлайн доступ] / https://arxiv.org/abs/2502.07950?utm_source=chatgpt.com
3. В Политехе прошёл Цифровой хакатон, 2025. [Онлайн доступ] / https://www.spbstu.ru/media/news/studencheskaya_zhizn/v-politekhe-proshyel-tsifrovoy-khakaton/

4. Кольская ГМК и Политех Петра Великого создают инновации для производства, 2025. [Онлайн доступ] / <https://kn51.ru/2025/02/20/kolskaya-gmk-i-politeh-petra-velikogo-sozdayut-innovaczii-dlya-proizvodstva/>

5. The Effects of Hackathons on the Entrepreneurial Skillset and Perceived Self-Efficacy as Factors Shaping Entrepreneurial Intentions, 2020. [Онлайн доступ] / https://www.mdpi.com/2076-3387/10/3/73?utm_source=chatgpt.com

TRAINING OF ENGINEERING AND TECHNICAL PERSONNEL ON THE ORDER OF INDUSTRIAL ENTERPRISES ON THE EXAMPLE OF A JOINT DIGITAL HACKATHON

Evgeny A. Batts^{1,a}, Yaroslav V. Kraynyuchenko^{2,b}, Konstantin K. Mashyanov^{3,c}

¹JSC «Kola Mining and Metallurgical Company», Monchegorsk Russia,

²Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

^aBattsEA@kolagmk.ru, ^bkraynyuchenkoyav@kolagmk.ru,

^cmashyanov_kk@spbstu.ru

Abstract. The article describes the experience of training engineering and technical specialists through a joint digital hackathon organized by Peter the Great St. Petersburg Polytechnic University and Kola MMC. The event involved solving applied industrial AI tasks based on anonymized hydrometallurgical production data, allowing students to acquire real-world competencies. The format demonstrated the effectiveness of integrating education and industry, as well as the development of students' technical and communication skills.

Keywords. Engineering education, digital hackathon, industrial AI, workforce training, machine learning, SPbPU, Kola MMC, project-based learning, university–industry collaboration.

* * *

АДАПТИВНАЯ СТАБИЛИЗАЦИЯ С ОБЕСПЕЧЕНИЕМ ЗАДАННОЙ ТОЧНОСТИ РЕГУЛИРОВАНИЯ

Гуков Артемий Алексеевич

Институт проблем машиноведения РАН, Санкт-Петербург, Россия
artemiy.gukoff4u@mail.ru

Аннотация. В статье исследуется задача адаптивной стабилизации минимально фазовой системы с произвольной относительной степенью и наличием параметрических неопределенностей. Предложен новый подход с интеграцией плотностной функции в контур управления, что позволяет внедрить возможность гибкого задания точности регулирования на уровне проектирования системы, исходя из конкретных приложений. Теоретические результаты подтверждены численным моделированием, демонстрирующим эффективность метода. Работа вносит вклад в развитие адаптивного управления, результат может найти применение в робототехнике, энергетике и других областях.

Ключевые слова. Адаптивное управление, стабилизация, управление, устойчивость, квадратичная функция, плотностная система, алгоритм адаптации.

Введение

Современные подходы к адаптивному управлению динамическими системами претерпели значительную эволюцию со времен первых работ, исследовавших возможности систем с самонастройкой в середине XX века. Исторически развитие адаптивного управления прошло несколько этапов: от простейших схем с эталонными моделями до современных методов, учитывающих структурные неопределенности [1-5].

В публикации [6] предложен новый взгляд на системы плотностного типа, которые представляют из себя систему, в которой можно выделить функцию «плотности» — нестационарный коэффициент, зависящий от текущего положения системы в пространстве. Данный подход является перспективным решением

для управления с заданной точностью регулирования на всем промежутке функционирования системы. В настоящей работе предложено расширение теории плотностных систем на адаптивное управление объектом с произвольной относительной степенью.

Постановка задачи

Рассмотрим динамическую систему

$$Q(p)y(t) = kR(p)u(t), \quad (1)$$

где $y(t) \in \mathbb{R}$ — доступный измерению выход системы, $u(t) \in \mathbb{R}$ — сигнал управления, $p = d/dt$ — оператор дифференцирования. Линейные дифференциальные операторы $Q(p)$ и $R(p)$ имеют нормализованные (т. е. с коэффициентами при старших степенях равными единице) характеристические полиномы с неизвестными коэффициентами $Q(s)$ и $R(s)$ соответственно, s — комплексная переменная. Полиномы $Q(s)$ и $R(s)$ имеют порядки n и m соответственно, полином $R(s)$ гурвицев. Высокочастотный коэффициент k известен. Предположим, что неизвестные коэффициенты $Q(s)$, $R(s)$, k и начальные условия принадлежат известному множеству Ξ .

Цель управления формулируется как

$$\lim_{t \rightarrow \infty} |y(t)| = 0 \quad (2)$$

Отметим, что в настоящей работе предложен подход, позволяющий добавить специальную функцию «плотности» в контур управления, в результате чего привести систему к системе плотностного типа [6]. Фактические характеристики системы такие, как точность регулирования зависят от выбора от выбора плотностной функции и остаются на усмотрение разработчика.

Основной результат

Синтез идеального закона управления. Представим полиномы $Q(s)$ и $R(s)$ в виде $Q(s) = Q_m(s) + \Delta Q(s)$ и $R(s) = R_m(s) + \Delta R(s)$.

Устойчивые полиномы $Q_m(s)$ и $R_m(s)$ имеют порядки n и m соответственно и выбираются специальным образом, о чем пойдет речь далее. Полиномы с неизвестными коэффициентами $\Delta Q(s)$ и $\Delta R(s)$ имеют порядки $n-1$ и $m-1$ соответственно. Введем вспомогательное управляющее воздействие $v(t)$, опираясь сначала на предположение, что его производные доступны измерению, в виде

$$u(t) = \frac{T(p)}{p} v(t), \quad (3)$$

где $T(p)$ — линейный дифференциальный оператор с устойчивым характеристическим полиномом $T(s)$, $\deg T(s) = n - m$. Важно отметить, что полиномы $Q_m(s)$, $R_m(s)$ и $T(s)$ выбираются так, чтобы выполнялось соотношение

$$Q_m(s) = R_m(s)T(s), \quad (4)$$

что всегда возможно сделать. Перепишем теперь уравнение объекта управления (1) в виде

$$Q_m(p)y(t) = kR_m(p)u(t) + k\Delta R(p)u(t) - \Delta Q(p)y(t), \quad (5)$$

где $D(s)$ — полином, зависящий от начальных условий, $\delta_0(t)$ — несмещенная дельта функция Дирака. Учитывая (3) и (4), приведем (5) к виду

$$y(t) = \frac{1}{p} \left(kv(t) + \frac{k\Delta R(p)}{R_m(p)} v(t) - \frac{p\Delta Q(p)}{Q_m(p)} y(t) + \frac{pD(p)}{Q_m(p)} \delta_0(t) \right). \quad (6)$$

Введем вектор постоянных неизвестных параметров $c_0^T = [c_{01} \ c_{02} \ c_{03}^T]$ и вектор регрессии $\omega^T(t) = [y(t) \ \zeta_y^T(t) \ \zeta_v^T(t)]$. Поясним как получены компоненты вектора c_0 . Скалярная компонента c_{01} получена в результате целочисленного деления в силу соотношения

$$\frac{p\Delta Q(p)}{Q_m(p)} = c_{01} + \frac{\Delta \tilde{Q}(p)}{Q_m(p)},$$

компоненты c_{02} и c_{03} состоят из коэффициентов многочленов $\Delta \tilde{Q}(s)$ и $k\Delta R(s)$ соответственно в силу того, что $\Delta \tilde{Q}(s) = c_{02}^T [1 \ s \ \dots \ s^{n-2}]^T$ и $k\Delta R(s) = c_{03}^T [1 \ s \ \dots \ s^{m-1}]^T$. Компоненты $\zeta_y(t)$ и $\zeta_v(t)$ могут получены, как состояния динамических фильтров

$$\begin{aligned} \dot{\zeta}_y(t) &= F_y \zeta_y(t) + b y(t), \\ \dot{\zeta}_v(t) &= F_v \zeta_v(t) + b v(t). \end{aligned} \quad (7)$$

Главные матрицы F_y и F_v заданы в форме Фробениуса и имеют $Q_m(s)$ и $R_m(s)$ соответственно в качестве сопровождающих полиномов. Вектор $b^T = [0 \ \dots \ 0 \ 1]$ в каждом отдельном случае имеет одинаковую структуру и размерность, понятную из контекста. Учитывая введенные величины, перепишем (6) в виде

$$\dot{y}(t) = kv(t) - c_0^T \omega(t) + d_0(t), \quad (8)$$

где $d_0(t) = \frac{pD(p)}{Q_m(p)} \delta_0(t)$ — экспоненциально затухающая, в силу устойчивости полинома $Q_m(s)$, величина. Выберем выражение для вспомогательного сигнала управления в виде

$$v(t) = \frac{1}{k} \left(c(t)^T \omega(t) + \tau \rho(y, t) \right), \quad (9)$$

где $c(t)$ — вектор настраиваемых параметров, $\rho(y, t)$ — плотностная функция, $\tau > 0$ — коэффициент усиления. Подставляя (9) в (8), имеем

$$\dot{y}(t) = (c(t) - c_0)^T \omega(t) + \tau \rho(y, t) + d_0(t). \quad (10)$$

Введем обозначения $\bar{d}_0 = \sup_{t, \Xi} d_0(t)$ и $\bar{c}_0 = \sup_{\Xi} c_0$. Сформулируем теорему.

Теорема. Пусть $\delta \in \mathbb{R}_{>0}$, $\mu \in \mathbb{R}_{>0}$ — константы, $\rho(y, t)$ такая, что $\rho(y, t)y(t) < 0$ при $y(t) > g(t)$ и $\rho(y, t)y(t) > 0$ при $y(t) < g(t)$ для

ограниченной функции $g(t)$. Тогда закон управления (3), (9) в купе с алгоритмом адаптации

$$\dot{c}(t) = -\alpha y(t)\omega(t) - \gamma c|y| \text{sign}(\rho(y, t)y) \quad (11)$$

приводит систему (10) к системе плотностного типа, обеспечивает ограниченность всех сигналов, а также достигается $\limsup_{t \rightarrow \infty} |y(t) - g(t)| < \delta$. Дополнительно, если выполнено соотношение

$$|\rho(y, t)| > \eta, \quad \eta = \frac{1}{(1-\mu)\tau} \left(\bar{d}_0 + \frac{\gamma}{2\alpha} \bar{c}_0^2 \right) \quad (12)$$

и $\lim_{t \rightarrow \infty} g(t) = 0$, то в система (10) достигнет цели управления (2).

Доказательство. Для упрощения изложения, опустим аргументы величин, которые сохраняются для введенных величин и понятны из контекста. Выберем квадратичную функцию V в виде

$$V = \frac{1}{2} y^2 + \frac{1}{2\alpha} (c - c_0)^T (c - c_0). \quad (13)$$

Учитывая соотношение

$$(c - c_0)^T c = -0,5(c - c_0)^T (c - c_0) - 0,5c^T c + 0,5c_0^T c_0.$$

Возьмем производную по времени от (13) вдоль траекторий (10), (11)

$$\begin{aligned} \dot{V} = & \tau \mu \rho y + \tau(1-\mu)\rho y + y d_0 - \\ & - \frac{\gamma}{2\alpha} \left(-(c - c_0)^T (c - c_0) - c^T c + c_0^T c_0 \right) |y| \text{sign}(\rho y). \end{aligned} \quad (14)$$

Рассмотрим сначала случай $y > g$. Учитывая оценки $y \leq |y| |\bar{d}_0| \leq |y| \bar{d}_0$ и $-(c - c_0)^T (c - c_0) - c^T c + c_0^T c_0 \leq c_0^T c_0 \leq \bar{c}_0^2$, оценим (14) в виде

$$\dot{V} \leq \tau \mu \rho(y, t)y - |y| \left((1-\mu)\tau |\rho(y, t)| - \bar{d}_0 - \frac{\gamma}{2\alpha} \bar{c}_0^2 \right). \quad (15)$$

Из (15) видно, что $\dot{V} \leq \tau \mu \rho(y, t)y < 0$ в области $D_S = \{(t, y) \in \mathbb{R}^2 | t \geq 0, y > g, |\rho| > \eta\}$. Аналогично можно показать, что в случае $y < g$, выполняется $\dot{V} \geq \tau \mu \rho(y, t)y > 0$ в области $D_U = \{(t, y) \in \mathbb{R}^2 | t \geq 0, y < g, |\rho| > \eta\}$. Таким образом, система устойчива в области D_S и неустойчива в области D_U . Тогда согласно утверждению 1 из [6], имеем $\limsup_{t \rightarrow \infty} |y - g| < \delta$. Кроме того, если выполняется (12), то получим $\lim_{t \rightarrow \infty} |y - g| = 0$. Наконец, если g выбрана так, что $\lim_{t \rightarrow \infty} g = 0$, то будет достигнута цель управления (2).

Покажем ограниченность сигналов в системе. Из (10) имеем предельную ограниченность $(c - c_0)^T \omega$, ограниченность ζ_y , следует из ограниченности y . Подставим (9) во второе уравнение (7), получим

$$\dot{\zeta}_v = \left(F_v + b \frac{1}{k} c_{03} \right) \zeta_v + b \frac{1}{k} (c - c_0)^T \omega + b \left(\frac{\tau}{k} \rho + \frac{1}{k} c_{01} y + \frac{1}{k} c_{02} \zeta_y \right).$$

Заметим, что матрица $F_v + b \frac{1}{k} c_{03}$ имеет гурвицев сопровождающий полином $R(s)$, а значит ζ_v предельно ограничен. Наконец, из $\limsup_{t \rightarrow \infty} |y - g| < \delta$, ограниченности g и предельной ограниченности всех компонент ω следует предельная ограниченность $\dot{c}$ и c . Теорема доказана.

Синтез реализуемого закона управления. Для формирования оценок на не доступные измерению производные $v(t)$, рассмотрим оценку $\tilde{v}(t)$, которую будем формировать с помощью наблюдателя с сильной обратной связью:

$$u(t) = \frac{T(p)}{p} \tilde{v}(t) \quad (16)$$

$$\dot{\xi}(t) = G_0 \xi(t) + D_0 (\tilde{v}(t) - v(t)), \quad \tilde{v}(t) = \xi_1(t), \quad (17)$$

где $\xi(t) \in \mathbb{R}^{n-m}$ — вектор оценок сигнала v и его производных,

$$G_0 = \begin{bmatrix} 0 & I_{n-m-1} \\ 0 & 0 \end{bmatrix}, \quad D_0^T = \begin{bmatrix} -\frac{d_1}{\mu} & -\frac{d_2}{\mu^2} & \dots & -\frac{d_{n-m}}{\mu^{n-m}} \end{bmatrix},$$

числа $d_i, i = \overline{1, (n-m)}$ такие, что $G = G_0 + D L_1$ — гурвицева, где

$L_1 = [1 \ 0 \ \dots \ 0]$, $D^T = [d_1 \ d_2 \ \dots \ d_{n-m}]$, $\mu > 0$ — достаточно малое число. Введем в рассмотрение вектор

$$\zeta(t) = \Gamma^{-1}(\xi(t) - \theta(t)), \quad \Gamma = \text{diag}\{\mu^{n-m-1}, \mu^{n-m-2}, \dots, \mu, 1\}, \quad (18)$$

где $\theta(t) = [v(t) \ \dot{v}(t) \ \dots \ v^{(n-m-1)}(t)]$. Далее запишем:

$$\tilde{v}(t) - v(t) = \mu^{n-m-1} \zeta_1(t) = \mu^{n-m-1} L_1 \zeta(t) \quad (19)$$

Учитывая (18) и (19), получим

$$\begin{aligned} \dot{y}(t) &= k \left((c(t) - c_0)^T \omega(t) + \tau \rho(y, t) + d_0(t) \right) + k \mu^{n-m-1} L_1 \zeta(t) \\ \mu \dot{\zeta}(t) &= G \zeta(t) - \mu b v^{(n-m)}(t) \end{aligned} \quad (20)$$

Достижение системой (20) при достаточно малом значении параметра μ тех же результатов, что и система (10) в теореме 1, можно показать схожим с теоремой 2 из [7] образом.

Моделирование

Рассмотрим объект управления (1) с дифференциальными операторами $Q(p) = p^3 - 3p^2 + 3p - 1$ и $kR(p) = p + 1$. Примем начальные условия $p^2 y(0) = p y(0) = 0$ и $y(0) = 1$. Зададим матрицы в фильтрах (7) в виде

$$F_v = -1, \quad F_y = \begin{bmatrix} 0 & 1 \\ -1 & -2 \end{bmatrix}.$$

Зададим функцию плотности в (9) в виде $\rho(y, t) = \ln \frac{g_s(t) - y(t)}{g_s(t) + y(t)}$.

Такое задание функции плотности обеспечивает нахождение траектории системы в подмножестве, ограниченном $g_s(t)$ и $g_s(t)$. Функция $g(t)$ из теоремы 1 при этом является их средним, то есть тождественно равна 0, а значит будет выполнена цель управления (2). Зададим $\tau = 1$, $\gamma = 1$, $\alpha = 1$. Результаты моделирования представлены на рис. 1 и 2.




Рис. 1. Стабилизация выхода системы




Рис. 2. График управляющего воздействия

Заключение

В данной работе предложен инновационный подход к адаптивной стабилизации динамических систем, основанный на интеграции плотностной функции в контур управления. Основным результатом исследования заключается в разработке алгоритма, который позволяет рассматривать объекты с произвольной относительной степенью и неизвестными параметрами.

Теоретически доказано, что предложенные закон управления и алгоритм адаптации гарантируют при правильном выборе плотностной функции достижение цели управления и обеспечивают ограниченность всех сигналов в системе. Результаты численного моделирования подтвердили эффективность метода. Дальнейшие исследования могут быть направлены на расширение класса рассматриваемых систем и оптимизацию выбора плотностной функции для достижения заданной точности регулирования.

Библиография

1. **Morse A. S.** Global stability of parameter adaptive control systems // IEEE Trans. Autom. Control. 1980. V. 25. № 3. P. 433–439.
2. **Morse A. S.** High-order parameter tuners for the adaptive control of nonlinear systems // US-Italy Seminar Syst. Model. Feedback Theor. Appl. 1992. V. 12. P. 339–364. https://doi.org/10.1007/978-1-4757-2204-8_23.
3. **Андриевский Б. Р., Фуртат И. Б.** Наблюдатели возмущений: методы и приложения. Часть 1. Методы // АиТ. 2020. № 9. С. 3–61.
4. **Sun J.** A modified model reference adaptive control scheme for improved transient performance // IEEE Trans. Autom. Control. 1993. V. 38. № 8. P. 1255–1259. <https://doi.org/10.1109/9.233162>.
5. **Morse A. S.** Supervisory Control of Families of Linear Set-Point Controllers-Part I. Exact Matching // IEEE Trans. Autom. Control. 1996. V. 41. № 10. P. 1413–1431. <https://doi.org/10.1109/9.539424>.
6. **Фуртат И. Б.** Плотностные системы. Анализ и управление // Автоматика и телемеханика. — 2023. — № 11. — С. 55–76.
7. **Гуков А. А.** Адаптивное управление по выходу с гарантией заданного качества регулирования // АиТ. — 2025. — № 5. — С. 26–38.

ADAPTIVE STABILIZATION WITH GUARANTEED CONTROL QUALITY

Artemii A. Gukov

Institute of Problems of Mechanical Engineering RAS, Saint-Petersburg,
Russia
artemiy.gukoff4u@mail.ru

Abstract. This paper investigates the problem of adaptive stabilization for minimum-phase systems with arbitrary relative degree and parametric uncertainties. A novel approach integrating a density function into the control loop is proposed, enabling flexible adjustment of regulation accuracy at the system design stage according to specific application requirements. Theoretical results are verified by numerical simulations demonstrating the method's effectiveness. The study contributes to the development of adaptive control, with potential applications in robotics, energy systems, and other engineering fields.

Keywords. Adaptive control, stabilization, stability, quadratic function, density-based control, adaptation algorithm.

* * *

УДК 330.1
doi:10.18720/SPBPU/2/id25-548

ИСПОЛЬЗОВАНИЕ КАСКАДОВ МОДЕЛЕЙ ДЛЯ РЕЗЮМИРОВАНИЯ ВСТРЕЧ

**Суин Алексей Евгеньевич¹, Серебряков Владислав Олегович²,
Чернышева Татьяна Юрьевна³**

Тюменский государственный университет, г. Тюмень, Россия

¹stud0000244131@utmn.ru, ²stud0000246870@utmn.ru,

³t.y.chernysheva@utmn.ru

Аннотация. В работе описывается система резюмирования встреч, которая работает с любыми аудио/видео источниками (включая записи с телефона), извлекает действия и задачи участников на русском и английском языках и интегрирует готовые LLM. Используются методы преобразования речи в текст (STT) и большие языковые модели (LLM) с приме-

нением промпт-инжиниринга для автоматизации суммаризации встреч. В качестве примеров приведены сравнения моделей STT (Speechmatics и Whisper) и различных подходов к промпт-инжинирингу (Zero-shot, Few-shot, Chain of Thought). Построена общая схема методики каскадной интеграции STT и LLM для извлечения и структурирования задач из аудиозаписей встреч. Описанная система позволит уменьшить нагрузку на секретарей, ускоряя процессы обсуждения и принятия решений. Решение особенно полезно для гибридных команд, нуждающихся в ясности после встреч без ограничений по платформе.

Ключевые слова. Большие языковые модели, интеллектуальный ассистент, интеллектуальное реферирование, автоматизация совещаний, преобразование речи в текст, промпт-инжиниринг, технологии GPT.

Введение

Современные менеджеры всё чаще сталкиваются с проблемами перегруженности количеством встреч. По данным исследований [1] руководители или менеджеры могут тратить более 60% своего рабочего времени на участие в совещаниях, при этом не редко вынуждены дополнительно тратить 20 %—30 % времени на обсуждения и разбор задач. Это снижает эффективность их работы и мешает сосредоточиться на личных задачах. Особенно актуально это в условиях гибридной работы, где потребность в автоматизации возросла [2]. В связи с количеством и частотой постановки задач некоторые из них могут быть упущены, что может быть серьезно для бизнеса. Для решения этой проблемой некоторые сервисы предоставляют возможности транскрибации речи в текст, например, Zoom и Otter.ai. Эти сервисы имеют свои ограничения: у них нет фокуса на контексте. Из-за чего они предоставляют “Стену текста” вместо структурированного списка задач; они не поддерживают русский язык; Zoom и Teams работают и сохраняют записи встреч лишь в своих экосистемах.

Большие языковые модели

Традиционные методы ручной записи протоколов и задач трудоемки и подвержены человеческим ошибкам, но современные

бизнес-процессы требуют эффективных решений для обработки больших объемов информации. Для этого на смену традиционным методам приходят большие языковые модели (Large language model, LLM), способные анализировать информацию с высокой точностью.

LLM являются лучшим инструментом для суммаризации благодаря пониманию контекста. В отличие от ранних алгоритмов, работавших по шаблонам, современные LLM (GPT, BERT) анализируют смысл текста, учитывая контекст и даже эмоциональную окраску. Это позволяет выделять не просто ключевые слова, а суть обсуждения.

Также LLM отличаются мультязычностью и адаптивностью. LLM обучаются на разнородных данных на многих языках, включая профессиональную лексику и сленг. Это критично для гибридных команд, где участники говорят на разных языках.

Промпты для больших языковых моделей и методики их формирования

Эффективное использование LLM требует грамотного подхода к формулированию задач для модели. Были рассмотрены такие методы промпт-инжиниринга как промпты без примеров (Zero-shot Prompting), промпты с примерами (Few-shot Prompting) и цепочки рассуждений (Chain of Thought, CoT) [6, 7, 8].

В ходе исследования оказалось, что различные виды встреч имеют разные приоритеты. Собеседования обычно строятся вокруг вопросов опрашиваемому и редко содержат какие-либо задачи для него. Во время совещаний распределение задач для решения обсуждаемых проблем наоборот является центральным. Необходимо разделить задачи при суммаризации разных видов встреч.

Наиболее эффективным решением оказались цепочки размышлений с примерами. Инструкция промпта поэтапно разделяет задачу модели. Первым этапом является определение вида встречи. От модели также требуется объяснение своего выбора. В зависимости от вида встречи последующие этапы различаются,

что позволяет модели точно выводить суммаризации для разных видов. Например, в участке промпта, отвечающем за инструкции для LLM, указано что «если эта встреча – конференция: выдели основную цель конференции; выдели основные вопросы и выводы приведённые каждым участником конференции; выведи поставленные участникам конференции замечания при наличии таковых; выведи поставленные участникам конференции задачи при наличии таковых.» После инструкций следуют примеры правильно оформленных суммаризованных текстов. Благодаря примерам, модель может правильно определить необходимые элементы обрабатываемых встреч и поддерживать устойчивый формат вывода. Вот экземпляр одного из примеров: «Пример собеседования: Основные темы разговора и ответы опрашиваемого: Личные данные: ФИО, возраст, семейное положение. Профессиональный опыт: предыдущее место работы, должность, стаж. Ожидания по зарплате: минимальная зарплата, максимальная зарплата. Причины ухода с предыдущей работы. Навыки и компетенции: оценка собственных навыков по 10-бальной шкале. Готовность к новой работе.» Он содержит в себе важные элементы собеседований с предполагаемыми ответами в оптимальном формате.

Выбор модели STT

Для обеспечения кросс-платформенности и поддержки русского языка была проведена оценка двух популярных моделей преобразования речи в текст (Speech to text, STT): Speechmatics [3] и Whisper [4]. Сравнение проводилось на основе метрики WER (Word Error Rate, ошибка распознавания слов) [5] на различных датасетах:

- Casual Conversation [9] – неформальные диалоги;
- Switchboard [10] – телефонные беседы между незнакомыми людьми;
- AVICAR [11] – речевые записи в условиях шума.

Таблица 1

Сравнение моделей STT

Модель	Преимущества	WER (%)	Поддерживаемые языки
Speechmatics	Распознавание голосов, работа с шумом, адаптация к акцентам	9.58 (Casual) 11.78 (Switchboard) 27.95 (AVICAR)	Более 30
Whisper	Открытый исходный код	11.82 (Casual) 22.33 (Switchboard) 50.34 (AVICAR)	Более 99

Анализ показал лучшую точность распознавания у модели Speechmatics, особенно в сложных условиях (шум, разговор с акцентом, низкое качество записи), превосходя Whisper на 2,24 % – 22,39%. Хотя Whisper имеет ряд преимуществ в виде бесплатности и широкой поддержки языков для дальнейшей реализации в системе была выбрана модель Speechmatics, поскольку она обеспечивает оптимальную точность и устойчивость к внешним помехам.

Результаты

Используя исследованные технологии, была разработана система, представляющая собой каскад STT и большой языковой модели. Схема работы системы представлена на рис. 1.

Модель Speechmatics транскрибирует записи с высокой точностью вне зависимости от качества. Отдельные участники встречи помечаются для их выделения на этапе суммаризации в случае необходимости (рис. 2).

Транскрибация записи передаётся вместе с инструкциями к LLM для суммаризации. На основе того, какой вид встреч следует суммаризовать, из каталога промптов выбирается нужный список задач. В итоге их выполнения выводится суммаризированный текст в необходимом формате. (рис. 3).




Рис. 1. Схема работы системы




Рис. 2. Транскрибация Speechmatics




Рис. 3. Вывод суммаризированного текста

Суммаризированные тексты были сравнены с эталоном для оценки качества. Поскольку для задачи более важно совпадение по содержанию чем по конкретным словам, была использована метрика BERTScore[12]. Значение F1score BERTScore для суммаризаций встреч составляет 0.78, что говорит об их близости к эталону.

Заключение

В данной работе предложена система автоматического извлечения задач из аудио— и видеозаписей встреч, поддерживающая многоязычный контент (включая русский и английский) и работающая с любыми источниками данных. Решение основано на интеграции современных моделей Speech-to-Text и больших языковых моделей (LLM), использующих промпт-инжиниринг для точного извлечения задач.

Исследование выполнено при поддержке Министерства науки и высшего образования Российской Федерации в рамках проекта (FEWZ-2024-0052).

Библиография

1. Carmeli, A., Galai, D., Waldman, D. A. Dear Manager, You're Holding Too Many Meetings [Электронный ресурс] // Harvard Business Review. —

2022. — 15 марта. — Режим доступа: <https://hbr.org/2022/03/dear-manager-youre-holding-too-many-meetings>, свободный. — Загл. с экрана.

2. **Kozlowski, S. W. J., Chao, G. T., Van Fossen, J.** Leading virtual teams [Текст] // Journal of Business Research. — 2023. — Т. 167. — С. 48–61. — DOI:10.1016/j.jbusres.2023.06.017. — Режим доступа: <https://www.sciencedirect.com/science/article/abs/pii/S0090261621000176?via%3Dihub>, для подписчиков.

3. Speechmatics. Официальный сайт [Электронный ресурс]. — URL: <https://www.speechmatics.com>, свободный. — Загл. с экрана.

4. OpenAI. Introducing Whisper [Электронный ресурс]. — URL: <https://openai.com/index/whisper/>, опубл. 2022. — Режим доступа: <https://openai.com/index/whisper/>, свободный. — Загл. с экрана.

5. **Zechner, K., Waibel, A.** 2000. Minimizing Word Error Rate in Textual Summaries of Spoken Language. In 1st Meeting of the North American Chapter of the Association for Computational Linguistics. [Текст] // ACL Anthology preprint A00-2025. — 2000. — Режим доступа: <https://aclanthology.org/A00-2025/>, свободный. — Загл. с экрана.

6. **Kojima, T., Reid, M., Matsuo, Y.** и др. Large Language Models are Zero-Shot Reasoners [Текст] // arXiv preprint arXiv:2205.11916. — 2022. — Режим доступа: <https://arxiv.org/abs/2205.11916>, свободный. — Загл. с экрана.

7. **Min, S., Lyu, X., Holtzman, A.** и др. Rethinking the Role of Demonstrations: What Makes In-Context Learning Work? [Текст] // arXiv preprint arXiv:2202.12837. — 2022. — Режим доступа: <https://arxiv.org/abs/2202.12837>, свободный. — Загл. с экрана.

8. **Wei, J., Wang, X., Schuurmans, D.** и др. Chain-of-Thought Prompting Elicits Reasoning in Large Language Models [Текст] // arXiv preprint arXiv:2201.11903. — 2022. — Режим доступа: <https://arxiv.org/abs/2201.11903>, свободный. — Загл. с экрана.

9. META AI. Casual Conversations Dataset [Электронный ресурс]. — URL: <https://ai.meta.com/datasets/casual-conversations-dataset/>, опубл. 2021. — Режим доступа: <https://ai.meta.com/datasets/casual-conversations-dataset/>, свободный. — Загл. с экрана.

10. Switchboard-1 Release 2 [Электронный ресурс] / Linguistic Data Consortium (LDC). — Philadelphia: LDC, 1997. — ISBN: 1-58563-121-3. — Режим доступа: <https://catalog.ldc.upenn.edu/LDC97S62>, свободный. — Загл. с экрана.

11. University of Illinois At Urbana-Champaign. AVICAR Corpus [Электронный ресурс]. — Режим доступа: <http://www.isle.illinois.edu/sst/AVICAR/#information>, свободный. — Загл. с экрана.

12. **Zhang, T., Kishore, V., Wu, F.** и др. BERTScore: Evaluating Text Generation with BERT [Текст] // arXiv preprint arXiv:1904.09675 — 2020. — Режим доступа: <https://arxiv.org/abs/1904.09675>, свободный. — Загл. с экрана.

USING MODEL CASCADES FOR MEETING SUMMARIZATION

**Suin Alexey Evgenievich¹, Serebryakov Vladislav Olegovich²,
Chernysheva Tatyana Yurievna³**

University of Tyumen, Tyumen, Russia,

¹stud0000244131@utmn.ru, ²stud0000246870@utmn.ru,

³t.y.chernysheva@utmn.ru

Abstract. The paper describes a meeting summarization system that processes any audio/video sources (including phone recordings), extracts action items and tasks in Russian and English, and integrates ready-to-use LLMs. The methods employed include speech-to-text (STT) conversion and large language models (LLMs) with prompt engineering for automated meeting summarization. Examples include comparisons of STT models (Speechmatics and Whisper) and different prompt engineering approaches (Zero-shot, Few-shot, Chain of Thought). A general methodology for cascaded integration of STT and LLM is developed to extract and structure tasks from meeting recordings. The proposed system reduces the workload on secretaries by accelerating discussion and decision-making processes. This solution is particularly useful for hybrid teams requiring clarity after meetings without platform restrictions.

Keywords. Large language models, intelligent assistant, automatic summarization, meeting automatization, speech-to-text, prompt engineering, GPT technologies.

* * *

ЭКСПЕРИМЕНТАЛЬНЫЙ АНАЛИЗ АГРЕССИВНОГО ПОВЕДЕНИЯ НА ГОРОДСКИХ ВИДЕО. ОТ СБОРА ДАННЫХ ДО СРАВНЕНИЯ МОДЕЛЕЙ

Каспицкий Алексей Александрович^{1,2,а}, Карякин Юрий Евгеньевич^{2,б}

¹ООО Бюджетные финансовые технологии, г. Тюмень, Россия,

²Тюменский государственный университет, г. Тюмень, Россия

^аa.kaspshitskii@bft.ru, ^бy.e.karyakin@utmn.ru

Аннотация. В работе рассмотрена задача автоматической бинарной классификации агрессивного и нормального поведения человека в городской среде. В качестве обучающего набора был собран собственный небольшой датасет, реализован полный пайплайн: сбор наборов движений по 16 кадров с уличных камер, полуавтоматическая разметка, обучение и сравнение моделей. Основная модель — ViViT, однако из-за малого объёма данных проведён сравнительный эксперимент с 3D-архитектурами (Conv3D, R(2+1)D и др.). Приведены метрики качества и анализ применимости подхода в реальных условиях. Новизна работы — практическая оценка эффективности современных и классических моделей на кастомном датасете в условиях дефицита данных.

Ключевые слова. Видео аналитика, классификация поведения, агрессивное поведение, ViViT, 3D сверточные сети, видео с уличных видеокамер, машинное обучение, собственный датасет, сравнение моделей.

Введение

В условиях растущей урбанизации и повсеместного распространения систем видеонаблюдения анализ поведения людей в городских пространствах становится практически реализуемой задачей. На каждом здании сегодня установлены камеры, которые непрерывно фиксируют обстановку. Однако, несмотря на огромный поток видеоданных, их потенциал часто используется лишь для пост-анализа, а не для оперативной аналитики в реальном времени. Автоматическая интерпретация поведения каждого че-

ловека на улице требует значительных вычислительных ресурсов и устойчивых алгоритмов, особенно в условиях высокой плотности объектов и шумовых помех.

Обзор существующих решений в области action recognition показывает: большинство моделей ориентированы на «сценическое» поведение (например, спортивные действия в датасетах UCF101 или HMDB51) или требуют специфических условий съёмки, мощных аппаратных подсистем и сложной ручной настройки, что ограничивает их применение в реальных городских сценах. Кроме того, во многих публикациях отсутствует полный pipeline, объединяющий детекцию, трекинг, буферизацию и классификацию в единую систему с возможностью передачи тревожных сигналов для последующего реагирования.

В рамках данной работы разработана система для классификации поведения человека в городской среде с ориентацией на работу в реальном времени. Ключевые компоненты системы включают:

- детекцию объектов (YOLO) [9];
- трекинг с сохранением идентификаторов (track_id);
- буферизацию клипов (16 кадров на каждый трек);
- классификацию поведения с помощью модели ViViT, обученной с нуля на собственном датасете; [1, 2, 3, 6]
- интеграцию с внешним тревожным сервисом (Spring Boot, Kotlin).

Ключевые особенности решения:

- ручная и полуавтоматическая разметка видеоданных;
- трек-ориентированная буферизация с сохранением метаданных (metadata.json);
- полное логирование и аудит аннотированных клипов;
- модульная архитектура, пригодная для промышленного внедрения.

Цель работы — представить архитектуру предложенной системы, методологию подготовки и аннотации данных, особенности обучения модели ViViT и результаты её оценки на ограниченном наборе данных. Особое внимание уделяется инженерным вызовам и практическим решениям, возникшим в процессе реализации.

Исходный код и инструменты доступны в публичном репозитории на GitHub. [15]

Постановка задачи

Описание предметной области. Современные городские пространства характеризуются высокой плотностью населения и интенсивным потоком событий, происходящих на улицах, в общественных местах, на транспортных узлах. Системы видеонаблюдения становятся основным инструментом мониторинга для обеспечения общественной безопасности, предотвращения и расследования инцидентов. Однако классическая аналитика чаще ориентирована на поиск статических объектов или событий, а не на интерпретацию динамики поведения человека.

Распознавание человеческих действий (action recognition) — отдельное направление компьютерного зрения, задачей которого является автоматическая идентификация типа активности или поведения по видеоряду. Несмотря на прогресс в этой области, большинство доступных датасетов (UCF101, HMDB51, Kinetics) [4, 5, 7, 8] слабо отражают специфику городской среды: они содержат преимущественно постановочные или однородные сцены с минимальным количеством шумов и простым фоном. В реальных же условиях города присутствует множество объектов, пересечений треков, смена ракурсов, плохое освещение и сложные формы поведения, что требует специализированных подходов и адаптированной архитектуры системы.

Определение проблемы. Основная задача — автоматическая бинарная классификация поведения человека на видео как «агрессивное» или «нормальное» с целью оперативного выявления потенциальных инцидентов. Существующие решения либо недостаточно устойчивы к городским условиям, либо не предусматривают полного замкнутого цикла от детекции до выдачи тревожного сигнала, либо требуют больших размеченных датасетов для обучения современных моделей (ViViT и аналогов) [10], что мало реализуемо в конкретном городском контексте. Ключевые ограничения и вызовы задачи:

Ограниченность размеченных данных: кастомный датасет мал по объёму, содержит только необходимые для задачи примеры поведения.

Требование к real-time обработке: высокая плотность событий и множество объектов требуют эффективности не только модели, но и всего пайплайна — от детекции до передачи тревожного сигнала.

Многообразие и шумность городской сцены: поведение людей часто неоднозначно, сцены многослойные, есть частичные перекрытия, артефакты и ошибки трекинга.

Практическая применимость: система должна быть легко масштабируема и интегрируема с внешними сервисами (например, модуль тревожных уведомлений).

Таким образом, задача формулируется как построение готового пайплайна, который способен на реальных видеоданных городской среды (с малым кастомным датасетом) автоматически выделять треки людей, буферизовать клипы и классифицировать поведение как агрессивное или нормальное, с минимизацией ложных срабатываний и максимальной устойчивостью к городским шумам.

Моделирование системы

Обоснование выбора языка моделирования. Для решения задачи бинарной классификации поведения человека на видео в городской среде в качестве основной архитектуры выбрана модель Video Vision Transformer (ViViT). Модель ViViT демонстрирует state-of-the-art-результаты на задачах action recognition, благодаря способности захватывать временные и пространственные зависимости без необходимости ручного проектирования признаков. Однако существенным ограничением ViViT и аналогичных архитектур является высокая требовательность к объёму размеченных данных — что делает их применение затруднительным в условиях малого кастомного датасета. [11, 12, 13, 14]

С учётом этого, в рамках экспериментов проведено сравнение с рядом трёхмерных сверточных архитектур, менее требовательных к количеству данных: Conv3D, R(2+1)D, R3D, MC3.

Альтернативные архитектуры служили для поиска оптимального баланса между качеством и устойчивостью классификации на ограниченных и шумных данных.

Построение модели. Общая архитектура решения включает следующие этапы.

Детекция объектов: для поиска людей на кадрах используется модель YOLO, обеспечивающая высокую скорость и устойчивость к городскому фону.

Трекинг объектов: детектированные объекты трекаются по уникальным идентификаторам (track_id). Это необходимо для последующей буферизации последовательных кадров одного и того же человека.

Буферизация клипов: для каждого трека сохраняется последовательность из 16 кадров, формируя короткий видеофрагмент (клип) с привязкой к метаданным (track_id, timestamp и др.).

Ручная и полуавтоматическая разметка данных: для формирования обучающей выборки реализован инструмент ручной аннотации клипов, с возможностью пред выставления класса на основе предварительного инференса (рис 1.)

Обучение моделей: на размеченном датасете обучается модель ViViT и альтернативные архитектуры. Проводится автоматизированное логгирование метрик, сохранение весов моделей и отчётов.

Инференс и интеграция: обученная модель используется для классификации новых клипов в режиме реального времени. Пред-




Рис. 1. Интерфейс для разметки данных

Таблица 1

Оценочные характеристики моделей

Модель	Accuracy (val)	F1-score (val)
r3d_18	64.71%	0.640
mc3_18	67.65%	0.660
r2plus1d_18	59.80%	0.705
conv3d_custom	62.75%	0.457
ViViT	50.98%	0.667

усмотрена интеграция с внешним тревожным сервисом (Spring Boot, Kotlin) для передачи тревожных сигналов через REST API.

Технические детали и организационные особенности:

- Для каждого клипа формируется файл metadata.json с основной информацией (track_id, метки, путь к кадрам).
- Полный цикл логирования и аудита данных (лог-файлы, отчёты по каждому этапу обработки).
- Хранение и версионирование моделей и отчётов.
- Инструменты для автоматической синхронизации с Google Colab и хранения датасета на Google Drive.

Результаты экспериментов. Для количественной оценки выбранных архитектур были проведены обучающие эксперименты на кастомном датасете, включающие по 5 эпох для каждой из классических 3D-моделей и 13 эпох для ViViT. В качестве основных метрик рассматривались Accuracy (точность) и F1-score на валидационной выборке. Ниже приведена сводная таблица (табл. 1) полученных результатов для пятой эпохи классических моделей и лучших эпох для ViViT.

Анализ результатов

Наибольший показатель точности (67.65%) показала архитектура mc3_18.

Самое высокое значение F1-score (0.705) – у r2plus1d_18, однако точность на этой архитектуре ниже.

Ключевые выводы

Применимость современных 3D-архитектур подтверждена даже на небольших и «грязных» городских датасетах.

Для достижения производственного качества требуется расширение выборки, аугментация и возможно — комбинация архитектур или self-supervised обучение.

Модульная структура системы и логирование на всех этапах позволяют легко интегрировать новые модели и источники данных.

Разброс по метрикам объясняется малым объёмом данных, разнородностью городских сцен и сложностью поведения для бинарной классификации.

Все тестируемые модели сходятся к умеренным значениям метрик, что указывает на возможность их применения даже на небольших датасетах, однако для повышения качества требуется либо рост данных, либо более сложная архитектура/аугментация.

Ниже представлена детализированная схема архитектуры системы BehaviorClassifier (рис 2.):

1. Видеоисточник → YOLO-детектор → Трекинг (track_id).
2. TrackClipBuffer сохраняет клипы и metadata.json.
3. Логика ручной разметки, логирования, синхронизации данных с Colab.
4. Инференс на модели ViViT (или других 3D CNN), отправка тревожного сигнала.
5. Вся история аннотаций и обработок ведётся для контроля качества.

Заключение

В работе представлен полный пайплайн для бинарной классификации агрессивного и не агрессивного поведения человека в городской среде на основе анализа видеопотоков. Система реализует все ключевые этапы: от детекции и трекинга объектов до буферизации, ручной аннотации, обучения и инференса современных моделей action recognition, а также интеграции с внешним тревожным сервисом.

Основная особенность подхода — использование собственного маломасштабного датасета с кастомной разметкой и ориентация на реальные городские сцены, отличающиеся высокой сложностью и шумностью. Эксперименты с архитектурами r3d_18, mc3_18, r2plus1d_18 и кастомной Conv3D показали, что даже при ограниченном количестве данных возможно достичь умеренного качества классификации (Acc до 67.7%, F1 до 0.71). При этом наблюдается существенная чувствительность моделей к структуре данных и классовому дисбалансу.




Рис. 2. Детализированная архитектура системы

Будущая работа будет направлена на расширение датасета, внедрение semi-supervised/active learning подходов и интеграцию дополнительных источников городских данных для улучшения устойчивости и точности классификации

Библиография

1. **Karpathy A., Toderici G., Shetty S.**, et al. Large-scale video classification with convolutional neural networks // Proceedings of the IEEE conference on Computer Vision and Pattern Recognition (CVPR). 2014. pp. 1725–1732.
2. **Simonyan K., Zisserman A.** Two-stream convolutional networks for action recognition in videos // Advances in Neural Information Processing Systems (NeurIPS). 2014. Vol. 27. pp. 568–576.
3. **Tran D., Wang H., Torresani L.**, et al. Learning spatiotemporal features with 3D convolutional networks // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2015. pp. 4489–4497.
4. **Kay W., Carreira J., Simonyan K.**, et al. The Kinetics human action video dataset // arXiv preprint arXiv:1705.06950. 2017.
5. **Carreira J., Zisserman A.** Quo vadis, action recognition? A new model and the Kinetics dataset // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017. pp. 6299–6308.
6. **Arnab A., Dehghani M., Heigold G.**, et al. ViViT: A Video Vision Transformer // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2021. pp. 6836–6846.
7. **Soomro K., Zamir A. R., Shah M.** UCF101: A dataset of 101 human actions classes from videos in the wild // arXiv preprint arXiv:1212.0402. 2012.
8. **Kuehne H., Jhuang H., Garrote E., Poggio T., Serre T.** HMDB: A large video database for human motion recognition // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2011. pp. 2556–2563.
9. **Redmon J., Farhadi A.** YOLOv3: An incremental improvement // arXiv preprint arXiv:1804.02767. 2018.
10. **Feichtenhofer C., Fan H., Malik J., He K.** SlowFast Networks for Video Recognition // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2019. pp. 6202–6211.
11. **Xu M., Yang L., Zhang H.**, et al. Learning to detect violent videos using convolutional neural networks // Proceedings of the International Conference on Multimedia Modeling. Springer, 2015. pp. 231–243.
12. **Ryoo M. S., Aggarwal J. K.** Recognition of composite human activities through context-free grammar based representation // Proceedings of the IEEE

Conference on Computer Vision and Pattern Recognition (CVPR). 2006. Vol. 2. pp. 1709–1718.

13. **Girdhar R., Carreira J., Doersch C., Zisserman A., Simonyan K.** Video action transformer network // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2019. pp. 244–253.

14. **Nagrani A., Albanie S., Zisserman A.** Seeing voices and hearing faces: Cross-modal biometric matching // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2018. pp. 8427–8436.

15. **Kapshtitskii A. A.** behaviorClassifier: Experimental pipeline for aggressive behavior recognition in urban videos : <https://github.com/mcdodik20008/behaviorClassifier> (дата обращения: 04.06.2025).

EXPERIMENTAL ANALYSIS OF AGGRESSIVE BEHAVIOR IN URBAN VIDEO. FROM DATA COLLECTION TO MODEL COMPARISON

Alex A. Kaspshitskii^{1,a}, Yuri E. Karyakin^{2,b}

¹LLC Budgetary Financial Technologies, Tyumen, Russia,

²Tyumen State University, Tyumen, Russia

^aa.kaspshitskii@bft.ru , ^by.e.karyakin@utmn.ru

Abstract. This paper addresses the task of automatic binary classification of aggressive and normal human behavior in urban environments. A custom, small-scale dataset was collected as a training set. The full pipeline was implemented: collecting motion sequences of 16 frames from street cameras, semi-automatic annotation, training, and model comparison. The primary model used is ViViT; however, due to the limited amount of data, a comparative experiment was conducted with 3D architectures (Conv3D, R(2+1)D, etc.). Quality metrics and an analysis of the applicability of the approach in real-world conditions are provided. The novelty of this work lies in the practical evaluation of both modern and classical models on a custom dataset under data scarcity conditions.

Keywords. Video analytics, behavior classification, aggressive behavior, ViViT, 3D convolutional networks, street surveillance video, machine learning, custom dataset, model comparison.

* * *

ГИБРИДНАЯ АНСАМБЛЕВАЯ МОДЕЛЬ, ОБЪЕДИНЯЮЩАЯ VAR, GRU И XGBOOST ДЛЯ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ

Зуауи Поль¹, Шкодырев Вячеслав Петрович²

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹paul.jean-zouaoui@mail.ru, ²shkodyrev@mail.ru

Аннотация. В данном исследовании предлагается гибридная ансамблевая модель, предназначенная для прогнозирования энергопотребления сталелитейного завода на различных временных горизонтах (1 час, 24 часа, 168 часов). Предлагаемая модель интегрирует модель Vector Autoregressive (VAR) и нейронные сети Gated Recurrent Unit (GRU) в качестве базовых моделей, а также алгоритм градиентного бустинга eXtreme Gradient Boosting (XGBoost), выступающий в роли мета-модели в рамках ансамблевой схемы. Данный подход был сопоставлен с традиционными статистическими методами и методиками на основе нейронных сетей для оценки его эффективности. Результаты показывают, что предложенный метод превосходит хорошо известные методы, испытанные в настоящем исследовании, для горизонтов в 24 и 168 часов. Эти улучшения обусловлены способностью архитектуры эффективно использовать различные модели прогнозирования совместно с эффективными стратегиями предварительной обработки данных, что в совокупности способствует повышению точности прогноза.

Ключевые слова. Предсказательная аналитика, Прогнозирование, Статистика, Промышленный искусственный интеллект, Нейронные сети, Машинное обучение, Ансамблевое обучение, Энергопотребление.

Введение

Точное прогнозирование потребления энергии имеет решающее значение для промышленного сектора. Заранее зная потребности в энергии, заводы могут регулировать производство или поставки в зависимости от пиковых значений или снижения по-

требления. Прогнозирование спроса на энергию позволяет производителям планировать закупки энергии по оптимальным ценам и избегать перерасхода ресурсов. Однако это является серьезной задачей ввиду большого количества параметров и нелинейной динамики систем. Мы представляем гибридную ансамблевую архитектуру, объединяющую VAR и GRU в качестве базовых моделей, дополненную мета-моделью XGBoost. Для оценки её эффективности мы проводим сравнения с несколькими широко используемыми методами прогнозирования. Используя набор данных, полученный с металлургического завода, расположенного в Южной Корее [1], наша оценка проводится по трем показателям: среднеквадратическая ошибка (MSE), средняя абсолютная ошибка (MAE) и коэффициент детерминации (R²).

Предиктивная аналитика и прогнозирование применяются в различных отраслях, включая финансы для предсказания цен акций [2], розничную торговлю для прогнозирования продаж [3], сельское хозяйство для прогнозирования урожая и энергетический сектор для прогнозирования потребления [4],[5]. В данной работе основное внимание уделяется последнему случаю. В последнее время благодаря увеличению вычислительных мощностей исследователи и инженеры проявляют растущий интерес к моделям машинного обучения, особенно основанным на нейронных сетях, которые демонстрируют улучшение точности прогнозирования в различных областях благодаря способности обрабатывать большие наборы данных и выявлять закономерности [6]. Модели на основе рекуррентных нейронных сетей широко используются в области прогнозирования энергопотребления благодаря своей способности учитывать долгосрочные зависимости, что обеспечивает большую точность прогноза по сравнению с традиционными полносвязанными нейронными сетями, которые не учитывают временные зависимости. Традиционные статистические методы, такие как (S)ARIMA или VAR, также демонстрируют устойчивые результаты в области прогнозирования энергопотребления. Тем не менее, эти методы предполагают линейную зависимость между прошлыми и будущими временными рядами, что делает их менее

эффективными для рядов с нелинейными паттернами [7]. Несмотря на это, они остаются высокоэффективными при правильной настройке параметров модели, как показано в многочисленных исследованиях. Обучение ансамблей – это перспективный подход, изучаемый учеными. Оно показывает, что ансамблевое прогнозирование обычно повышает точность прогноза [8]. Существует несколько методов ансамблевого обучения, среди наиболее известных можно назвать мешок (bagging), стекинг (stacking) и бустинг (boosting) [9]. Основная идея заключается в комбинировании различных моделей для достижения более точных результатов.

Постановка задачи

Описание набора данных. Целевой переменной является «Usage_kWh» для горизонтов прогнозирования на 1 час, 24 часа и 168 часов. Датасет содержит данные о потреблении энергии (в кВт·ч) на заводе, регистрируемые каждые 15 минут в течение 365 дней [10].

Таблица 1

Список переменных

Variable name	Units	Type
Date		Date
Usage_kWh	kWh	Continuous
Lagging_Current_Reactive.Power_kVarh	kVarh	Continuous
Leading_Current_Reactive_Power_kVarh	kVarh	Continuous
CO2(tCO2)	Ppm	Continuous
Lagging_Current_Power_Factor	%	Continuous
Leading_Current_Power_Factor	%	Continuous
NSM	s	Continuous
WeekStatus		Categorical
Day_of_week		Categorical
Load_type		Categorical




Рис. 1. Потребление энергии (Usage_kWh) во времени за период семи недель

Для уменьшения объема данных мы выбрали одну точку в час, что позволило сохранить ключевые закономерности и тенденции, а также упростить обработку и интерпретацию данных. Наблюдается выраженная суточная и недельная сезонность: в будние дни потребление энергии значительно выше, чем в выходные.

Математическая постановка задачи. Задача состоит в прогнозировании потребления энергии сталелитейным заводом на следующие N временных шагов. Имеются наблюдаемые значения за предыдущие k временных шагов $X_t, X_{t-1}, \dots, X_{t-k}$, где X – входная матрица размера (n, k) , n обозначает количество признаков, а k – длину временного окна. Цель состоит в том, чтобы спрогнозировать значения потребления энергии на следующие N временных шагов, обозначаемые как $\widehat{E}_{t+1}, \widehat{E}_{t+2}, \dots, \widehat{E}_{t+N}$, с использованием предиктивной модели F .

$$\widehat{E}_{t+1}, \widehat{E}_{t+2}, \dots, \widehat{E}_{t+N} = F(X_t, X_{t-1}, \dots, X_{t-k}).$$

В данном исследовании используется подход, основанный на технике стекинга, который сочетает Vector Autoregression (VAR) и Gated Recurrent Unit (GRU) в качестве базовых моделей с целью захвата как линейных, так и нелинейных временных зависимостей в данных. Различные модели дополняют друг друга: VAR используется для моделирования линейных зависимостей между множеством временных рядов, тогда как GRU учится выявлять сложные

нелинейные взаимосвязи и долговременные паттерны. Алгоритм экстремального градиентного бустинга (XGBoost) выступает в роли метамодели, агрегируя прогнозы базовых моделей. Это позволяет надежно управлять остаточными ошибками и повышать точность прогнозов за счёт техники градиентного бустинга. Данная модель направлена на использование разнообразия моделей и снижение как смещения (bias), так и дисперсии (variance) в прогнозировании временных рядов. Таким образом, итоговый выход системы можно представить следующим образом:

$$y_{XGB}^*(t) = f_{XGB}(x(t));$$

$$x(t) = [\hat{y}_{VAR}(t); \hat{y}_{GRU}(t); Day_sin(t);$$

$$Day_cos(t); WeekStatus_Weekend(t)],$$

где $\hat{y}_{VAR}(t)$ — прогнозы, сделанные моделью VAR; $\hat{y}_{GRU}(t)$ — прогнозы, полученные моделью GRU; $Day_sin(t)$ — синусоидальное представление даты; $Day_cos(t)$ — косинусоидальное представление даты; $WeekStatus_Weekend(t)$ — закодированные признаки переменной «WeekStatus».

Целью работы является минимизация расхождения между фактическими значениями энергопотребления и теми, которые были спрогнозированы моделью F. Соответственно, целевую функцию потерь можно определить следующим образом, где $\hat{E}_t$,

обозначает прогнозируемое энергопотребление, а E_t , истинное значение:

$$\mathcal{L} = \sum_{t=0}^T \hat{E}_t - E_t \Rightarrow \min$$

Ансамблевое обучение. Ансамблевое обучение — это метод машинного обучения, основанный на объединении нескольких моделей с целью повышения точности прогнозирования [11]. За счёт комбинирования различных моделей ансамблевые методы позволяют снизить общую ошибку прогнозов, сохраняя при этом преимущества и сложность каждой отдельной модели. Согласно проведённым исследованиям по данной теме, чем больше моделей используется, тем точнее становятся прогнозы, получаемые с помощью ансамблевой модели [9].

Предварительная обработка данных

Выбор подходящей модели играет ключевую роль в науке о данных, однако одним из важнейших этапов является фаза предварительной обработки данных. На этом этапе решаются проблемы, связанные с выбросами [12], аномалиями [13] и отсутствующими данными, а также извлекаются дополнительные релевантные признаки, что существенно улучшает производительность моделей [14].

Вейвлетное шумоподавление. В данном исследовании для шумоподавления сигнала используется вейвлет-преобразование. Применяется многомасштабное разложение первого уровня с вейвлетом Даубеши 1 (Daubechies 1) для разложения исходного сигнала «Usage_kWh» на компоненты низкой и высокой частоты. В результате разложения получают коэффициенты A1 (низкочастотные) и D1 (высокочастотные). Затем шум в высокочастотных компонентах уменьшается с помощью мягкого порогового значения 0.1, применённого к коэффициентам D1. Наконец, для восстановления отфильтрованного сигнала используется обратное дискретное вейвлет-преобразование с модифицированными коэффициентами.




Рис. 2. Схематическое изображение гибридной ансамблевой модели

One-Hot кодирование категориальных переменных для совместимости с моделью. Чтобы предложенная модель могла интерпретировать категориальные переменные, их необходимо закодировать. В данном исследовании для представления категориальных переменных в виде бинарных векторов используется one-hot кодирование. Для переменной с K уникальными категориями каждая категория кодируется вектором длины K , в котором все элементы равны нулю, за исключением одного элемента, равного единице, расположенного на позиции, соответствующей данной категории.

$$\delta_{x, c_i} = \begin{cases} 1 & \text{if } x = c_i; \\ 0 & \text{else,} \end{cases}$$

где $x \in \{c_1, c_2, \dots, c_K\}$ – категориальная переменная с K классами; Функция one-hot кодирования $\phi: \{c_1, \dots, c_K\} \rightarrow \{0, 1\}^K$ определяется как $\phi(x) = (\delta_{x, c_1}, \delta_{x, c_2}, \dots, \delta_{x, c_K})$.

Следующие переменные были закодированы: Day_of_Week, WeekStatus и Load_type.

Кодирование циклического времени с использованием синусоидального и косинусоидального преобразований. Чтобы модель могла учитывать сезонность и избежать разрывов между началом и концом суток, циклические данные, представленные в столбце даты и времени, преобразуются с использованием периодического представления с помощью синусоидальных и косинусоидальных функций. Это преобразование можно представить следующим образом:

$$\text{Daysin}(t) = \sin\left(\frac{2\pi}{86400} \cdot t\right)$$

$$\text{Daycos}(t) = \cos\left(\frac{2\pi}{86400} \cdot t\right)$$

Удаление мультиколлинеарности. И, ненужные столбцы были удалены с использованием корреляционной матрицы в соответствии со следующей гипотезой: “The central hypothesis is that good feature sets contain features that are highly correlated with the class, yet uncorrelated with each other”[15]. Мы удалили переменную Leading_

Current_Reactive_Power_kVarh, которая имеет корреляцию -0.94 с Leading_Current_Power_Factor, и переменную Lagging_Current_Reactive.Power_kVarh, которая коррелирует на 0.88 с CO2(tCO2).

Изначально набор данных содержал 11 столбцов, а после обработки данных их количество увеличилось до 17.

Конфигурация модели

Базовые модели: GRU и VAR. В качестве базовых моделей гибридной ансамблевой модели используются Gated Recurrent Unit (GRU) и Vector Autoregressive (VAR).

Модель Gated Recurrent Unit (GRU) настроена следующим образом:

- Архитектура: четыре слоя – два слоя GRU, за которыми следуют два полносвязных (dense) слоя.
- Функции активации: ReLU для второго слоя GRU; линейная активация для первого полносвязного слоя.
- Оптимизатор: Adam.
- Функция потерь: среднеквадратичная ошибка (MSE).
- Обучение: 80 эпох с ранней остановкой и динамической настройкой скорости обучения.

Модель VAR (Vector Autoregressive) может быть определена следующей функцией:

$$\text{VAR_kWh}_{t+h} = c + \sum_{i=1}^{30} \left(\begin{aligned} & a_i \cdot \text{kWh}_{t+h-i} + \\ & + b_i \cdot \text{CO2}_{t+h-i} + \\ & + d_i \cdot \text{Leading_CPF}_{t+h-i} + \\ & + e_i \cdot \text{Lagging_CPF}_{t+h-i} + \\ & + f_i \cdot \text{NSM}_{t+h-i} + \\ & + g_i \cdot \text{date_cos}_{t+h-i} + \\ & + h_i \cdot \text{date_sin}_{t+h-i} + \\ & + \sum_{j=1}^2 i_{ij} \cdot \text{WeekStatus}_{t+h-i} + \\ & + \sum_{j=1}^6 k_{ij} \cdot \text{Day_of_week}_{j, t+h-1} + \\ & + \sum_{j=1}^2 l_{ij} \cdot \text{Load_type}_{j, t+h-1} \end{aligned} \right) + e_t.$$

Мета-модель: XGBoost. Extreme Gradient Boosting (XGBoost) — самая популярная реализация градиентного бустинга. Согласно документации, “XGBoost is an optimized distributed gradient boosting library, designed to be highly efficient, flexible and portable” [16]. В предлагаемом методе модель XGBoost используется для агрегирования предсказаний моделей VAR и GRU, обеспечивая итоговые прогнозы.

Результаты экспериментов






Рис. 3. Графическое представление результатов для горизонтов прогнозирования 1 час, 24 часа и 168 часов (пример)

Период тестирования для горизонта прогнозирования в 1 час охватывал временной интервал с 26.11.2018 08:00:00 до 27.11.2018 07:00:00, в то время как для горизонтов в 24 и 168 часов — с 26.11.2018 08:00:00 до 03.12.2018 07:00:00. Для сравнения с существующими моделями все методы (кроме предложенной) оценивались только по исходным числовым признакам (с шагом в 1 час, а не 15 минут), без использования предложенных этапов обработки данных и продвинутых методов обучения, таких как динамическая настройка скорости обучения или ранняя остановка в нейронных сетях.

Предлагаемый метод продемонстрировал наилучшие показатели по каждому из оценочных критериев для горизонтов прогнозирования в 24 и 168 часов. Однако для одного часа его эффективность оказалась ниже, чем у некоторых других моделей (например, SARIMA).

MAE: Гибридная ансамблевая модель показала наименьшие значения средней абсолютной ошибки для горизонта прогнозирования в 24 и 168 часов (9,72 для 1 часа, 11,5 для 24 часов и 13,34 для 168 часов). Однако для горизонта в один час она предоставила ме-

Таблица 2

**Сравнительные результаты между существующими методами
и предлагаемым методом**

	1 hour	24 hours	168 hours (1 week)	
LSTM (Univariate)	8,23	16,08	21,37	MAE
GRU (Univariate)	9,05	19,75	22,11	
SARIMA	5,84	14,32	13,96	
Prophet	16,37	17,51	17,28	
VAR	10,26	14,73	14,23	
N-BEATS	7,56	17,83	17,83	
Proposed method	9,72	11,5	13,34	
LSTM (Multivariate)	152	582	741	MSE
GRU (Multivariate)	185	727	898	
SARIMA	97	522	521	
Prophet	413	528	521	
VAR	200	460	534	
N-BEATS	142	666	666	
Proposed method	246	368	493	
LSTM (Univariate)	0,86	0,44	0,29	R2
GRU (Multivariate)	0,84	0,3	0,14	
SARIMA	0,91	0,5	0,5	
Prophet	0,64	0,49	0,5	
VAR	0,82	0,56	0,49	
N-BEATS	0,87	0,36	0,36	
Proposed method	0,78	0,64	0,53	

нее точные результаты по сравнению с моделями SARIMA, VAR, LSTM, GRU и N-BEATS. В целом же прогнозы близки к фактическим значениям.

MSE: Гибридная ансамблевая модель снова показала наименьшие значения среднеквадратичной ошибки для горизонтов в 24 и 168 часов, но более высокое значение MSE для одночасового горизонта (246 для 1 часа, 368 для 24 часов и 493 для 168 часов). Это подтверждает способность модели минимизировать значительные отклонения, особенно для длинных горизонтов прогнозирования.

R2: С коэффициентом детерминации, превышающим показатели других моделей для горизонтов 24 и 168 часов (0,78 для 1 часа, 0,64 для 24 часов и 0,53 для 168 часов), гибридная ансамблевая модель демонстрирует наилучшее соответствие структуре данных для горизонтов прогнозирования в 24 и 168 часов.

Заключение

Прогнозирование временных рядов — активно развивающаяся область исследований в промышленности, науке и инженерии, где повышение точности предсказаний остаётся постоянной задачей. течением времени было разработано множество подходов, включая как статистические методы, так и модели на основе нейронных сетей, каждая из которых обладает своими преимуществами и недостатками. В настоящей работе нами была предложена методика, сочетающая сильные стороны как классических статистических моделей, таких как VAR, так и моделей на основе нейронных сетей. Эта модель, построенная на принципах ансамблевого обучения, демонстрирует возможность повышения качества прогнозирования по сравнению с устоявшимися методами для среднесрочного и долгосрочного горизонтов (1 сутки и 1 неделя). Более того, этап предварительной обработки данных оказался критически важным компонентом предложенного метода и сыграл значительную роль в повышении эффективности прогнозов. Полученные результаты подчеркивают потенциал гибридных и ансамблевых подхо-

дов в прогнозировании временных рядов и подтверждают важность этапа обработки данных для достижения высокой точности прогнозов.

Библиография

1. **Sathishkumar V E, C. S.** Steel Industry Energy Consumption, <https://archive.ics.uci.edu/dataset/851>, (2021).
2. **Bao, W., Cao, Y., Yang, Y., Che, H., Huang, J., Wen, S.** Data-driven stock forecasting models based on neural networks: A review. *Inf. Fusion.* 113, 102616 (2025). <https://doi.org/10.1016/j.inffus.2024.102616>.
3. **Hurtado-Mora, H. A., García-Ruiz, A. H., Pichardo-Ramírez, R., González-del-Ángel, L. J., Herrera-Barajas, L. A.** Sales Forecasting with LSTM, Custom Loss Function, and Hyperparameter Optimization: A Case Study. *Appl. Sci.* 14, 9957 (2024). <https://doi.org/10.3390/app14219957>.
4. **Nichiforov, C., Stamatescu, I., Făgărășan, I., Stamatescu, G.** Energy consumption forecasting using ARIMA and neural network models. In: 2017 5th International Symposium on Electrical and Electronics Engineering (ISEEE). pp. 1–4 (2017).
5. LSTM based long-term energy consumption prediction with periodicity — ScienceDirect, <https://www.sciencedirect.com/science/article/abs/pii/S0360544220303042>.
6. **Averkin, A., Yarushev, S.** Hybrid Neural Networks for Time Series Forecasting. In: Kuznetsov, S.O., Osipov, G.S., and Stefanuk, V.L. (eds.) *Artificial Intelligence*. pp. 230–239. Springer International Publishing, Cham (2018).
7. **Zheng, J., Xu, C., Zhang, Z., Li, X.** Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network. In: 2017 51st Annual Conference on Information Sciences and Systems (CISS). pp. 1–6 (2017).
8. **Wu, H., Levinson, D.** The ensemble approach to forecasting: A review and synthesis. *Transp. Res. Part C Emerg. Technol.* 132, 103357 (2021). <https://doi.org/10.1016/j.trc.2021.103357>.
9. Qu'est-ce que l'apprentissage ensembliste ? | IBM, <https://www.ibm.com/fr-fr/think/topics/ensemble-learning>.
10. **EASWARAMOORTHY, S.:** Steel Industry Energy Consumption, <https://iee-dataport.org/documents/steel-industry-energy-consumption>, (2022).
11. **Zhou, Z.-H.** *Ensemble Methods: Foundations and Algorithms*. CRC Press (2012).
12. Detecting time series outliers, <https://robjhyndman.com/hyndsight/tsoutliers/>.

13. **Boniol, P., Paparrizos, J., Palpanas, T.** New Trends in Time Series Anomaly Detection, <https://openproceedings.org/2023/conf/edbt/3-paper-200.pdf>, (2023).

14. **Tawakuli, A., Havers, B., Gulisano, V., Kaiser, D., Engel, T.** Survey: Time-series data preprocessing: A survey and an empirical analysis. *J. Eng. Res.* (2024). <https://doi.org/10.1016/j.jer.2024.02.018>.

15. **Hall, M. A.** Correlation-based Feature Selection for Machine Learning.

16. XGBoost Documentation — xgboost 3.0.1 documentation, https://xgboost.readthedocs.io/en/release_3.0.0/.

HYBRID ENSEMBLE MODEL COMBINING VAR, GRU AND XGBOOST FOR ENERGY CONSUMPTION FORECASTING

Paul Zouaoui¹, Viacheslav P. Shkodyrev²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹paul.jean-zouaoui@mail.ru, ²shkodyrev@mail.ru

Abstract. In this study, a hybrid ensemble model is proposed to forecast energy consumption of a steel plant at different time horizons (1 hour, 24 hours, 168 hours). The proposed model integrates the Vector Autoregressive (VAR) model and Gated Recurrent Unit (GRU) neural networks as base models, along with the Extreme Gradient Boosting (XGBoost) algorithm serving as a meta-model in an ensemble scheme. This approach was compared with traditional statistical methods and neural network-based techniques to evaluate its effectiveness. The results show that the proposed method outperforms well-known methods tested in this study for 24-hour and 168-hour horizons. These improvements are due to the architecture's ability to effectively utilize various prediction models together with efficient data preprocessing strategies, which collectively contribute to improving forecast accuracy.

Keywords. Predictive analytics, Forecasting, Statistics, Industrial AI, Neural Networks, Machine Learning, Ensemble Learning, Energy Consumption

* * *

ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АВТОМАТИЧЕСКОЙ СЕГМЕНТАЦИИ ПОЗВОНОЧНИКА В СИСТЕМАХ ПОДДЕРЖКИ ВРАЧЕБНЫХ РЕШЕНИЙ

Мищенко Илья Игоревич¹, Мисник Антон Евгеньевич²

Белорусско-Российский университет, г. Могилёв, Республика Беларусь

¹sombra74@yandex.by, ²anton@misnik.by

Аннотация. В работе описан модуль автоматической сегментации позвоночника, разработанный для системы поддержки принятия врачебных решений (СППВР). В качестве ядра использована свёрточная нейронная сеть YOLOv11, что позволило заменить традиционные процедуры фильтрации и эквализации на глубокий нейросетевой анализ. Модель обучена на размеченных в CVAT рентгеновских снимках; её средняя точность локализации позвоночника и отдельных позвонков достигает 95% при доверии свыше 75%. Архитектура СППВР реализована по модульному принципу и включает блоки предварительной обработки изображений, сегментации, вычисления диагностических параметров и визуализации результатов, что обеспечивает гибкую интеграцию решения в медицинские информационные системы. Полученные координаты позвонков используются для построения сплайн-аппроксимации позвоночного столба и расчёта угловых отклонений, позволяя автоматически выявлять деформации и формировать предварительные заключения о сколиозе, кифозе и Hip-spine синдроме. Внедрение модуля сокращает время анализа снимков и повышает воспроизводимость диагностики, демонстрируя потенциал нейросетевых методов в задачах медицинского компьютерного зрения.

Ключевые слова. Компьютерное зрение, YOLOv11, сегментация позвоночника, медицинская диагностика, нейронные сети, система поддержки принятия решений.

Введение

Системы поддержки принятия врачебных решений (СППВР) становятся важным инструментом в современной медицине. Они

обеспечивают автоматизацию анализа медицинских изображений, снижают нагрузку на специалистов и повышают точность диагностических выводов. Одной из основных задач таких систем в травматологии является точная идентификация анатомических структур, например, позвоночника и его элементов, что важно для диагностики травм и патологий. Настоящая работа выполнена в рамках проекта по разработке интеллектуальной системы поддержки принятия врачебных решений для нужд Федерального центра травматологии, ортопедии и эндопротезирования (г. Смоленск), ориентированного на внедрение автоматизированных методов анализа рентгеновских снимков позвоночника в клиническую практику.

Традиционные подходы включают в себя методы предварительной обработки (например, эквализация, медианная фильтрация) и алгоритмы выделения анатомических ориентиров (Shi-Tomasi, SIFT). Однако такие подходы зависят от качества изображений и требуют ручной настройки.

В данной статье предложен новый подход: автоматическая сегментация позвоночника на основе свёрточной нейронной сети YOLOv11, интегрированная в СППВР как отдельный модуль. Этот подход устраняет необходимость ручного выделения ориентиров, обеспечивая автоматическое обнаружение позвоночника и позвонков с последующим расчетом диагностических параметров.

Архитектура СППВР

Разрабатываемая система поддержки принятия врачебных решений построена по модульному принципу, где каждый функциональный блок отвечает за отдельный этап обработки и анализа медицинских изображений. Такой подход позволяет гибко масштабировать систему, интегрировать новые технологии и адаптировать её под различные клинические сценарии. Архитектура включает в себя четыре последовательно взаимодействующих компонента: модуль загрузки и предварительной обработки изображений, модуль сегментации и анализа позвоночника с применением




Рис. 1. Блок-схема основных модулей системы поддержки принятия врачебных решений

нейросетевых алгоритмов, блок автоматической постановки диагноза и модуль визуализации и сохранения данных [8].

На рис. 1 показана блок-схема основных модулей системы поддержки принятия врачебных решений.

Функционирование системы начинается с конвертации входных рентгеновских снимков из формата DICOM в PNG с сохранением всех важных метаданных. Далее выполняется коррекция глубины цвета, подавление шумов с помощью медианной фильтрации и улучшение контраста путём адаптивной эквализации гистограммы (CLAHE). Эти процедуры позволяют устранить визуальные искажения, вызванные неравномерным освещением. Изображения масштабируются до унифицированного разрешения и нормализуются по интенсивности пикселей, что необходимо для корректной работы нейросетевых алгоритмов на последующих этапах [8].

Пример предварительной обработки изображения представлен на рис. 2.

Главное место в архитектуре СППВР занимает модуль сегментации и анализа позвоночника, реализованный на базе сверточной нейронной сети YOLOv11. [5] Данный модуль отвечает за автоматическое обнаружение и локализацию позвоночного столба и отдельных позвонков на рентгеновских изображениях [3].

Разработка модуля началась с формирования обучающего датасета. Для этой цели использованы оригинальные рентгеновские снимки, размеченные вручную в среде CVAT. В процессе разметки каждому объекту: позвоночнику в целом и каждому позвонку в отдельности — присвоен уникальный класс и координаты ограничивающих рамок. [1] Разметка сохранена в формате, совместимом с архитектурой YOLO, и далее преобразована в необходимый

формат для обучения с использованием стандартных утилит фреймворка PyTorch [6].

После подготовки датасета настроена и обучена свёрточная нейронная сеть YOLOv11, адаптированная под задачу медицинской сегментации. Обучение проводилось на GPU с применением аугментаций и регуляризаций для повышения обобщающей способности модели. [6] Учитывая вариативность анатомических зон, в процессе обучения обеспечен баланс классов. [2] По результатам валидации модель продемонстрировала высокую точность детекции отдельных позвонков (до 95 %) с уровнем уверенности распознавания выше 75 %.




Рис. 2. Рентгеновский снимок до и после предварительной обработки

Результаты нейросетевого анализа представлены в виде визуализированных ограничивающих рамок на исходных изображениях, а также в формате текстового файла. Структура этих файлов соответствует стандарту YOLO: каждая строка содержит идентификатор класса, нормализованные координаты центра рамки, её ширину, высоту и значение уровня уверенности распознавания.

На рис. 3 показаны готовые изображения с результатами нейросетевого анализа.




Рис. 3. Готовые изображения с результатами нейросетевого анализа

На следующем этапе данные, полученные от модели YOLO, подвергаются дополнительной обработке. Центры масс всех обнаруженных позвонков извлекаются из выходных файлов и упорядочиваются по вертикали. Далее эти точки соединяются в ломаную линию, которая аппроксимируется гладкой кривой методом сплайновой интерполяции. На основе этой кривой система вычисляет углы отклонения и степени деформации позвоночника. Такой подход исключает необходимость применения дополнительных алгоритмов поиска анатомических ориентиров, поскольку координаты всех необходимых точек уже определены нейросетевой моделью. Кроме того, использование данной архитектуры делает систему менее чувствительной к шумам, артефактам и вариациям освещённости по сравнению с традиционными методами сегментации, такими как фильтрация или гистограммная эквализация [8].

Полученные геометрические параметры, включая углы наклона, величины смещений и отклонений, передаются в модуль автоматической постановки диагноза. Здесь система выносит предварительные заключения о наличии возможных патологий, таких как сколиоз, кифоз, при наличии информации о тазовом суставе и Нир-спине синдром, а также фиксирует зоны аномального искривления. При необходимости информация дополняется рекомендациями по дальнейшему обследованию [7].

На рис. 4 представлены визуализированные результаты: центры масс позвонков, траектория их пространственного распределения и аппроксимирующая кривая, используемая для оценки отклонений.

Для представленных рисунков среднее общее отклонение в первом случае составляет $2,41^\circ$, а во втором $3,62^\circ$, что подтверждает отсутствие сколиоза.

Завершающим компонентом архитектуры является модуль визуализации и сохранения данных, который обеспечивает графическое представление результатов анализа, а также их долговременное хранение в соответствии с требованиями медицинского документооборота. Визуализация включает нанесение на обрабо-




Рис. 4. Визуализированные результаты: центры масс позвонков, траектория их пространственного распределения и аппроксимирующая кривая, используемая для оценки отклонений

танные рентгеновские изображения номеров обнаруженных позвонков, отображение аппроксимированной кривой позвоночного столба и аннотаций с диагностическими параметрами, такими как углы искривления и смещения. Сформированные же отчёты предназначены для врачебного анализа и включают информацию, необходимую для принятия клинических решений. Все результаты, включающие изображения, выходные данные нейросетевого

модуля и заключения автоматически сохраняются в структурированном виде и могут экспортироваться в форматах, совместимых с медицинскими информационными системами. Благодаря этому обеспечивается возможность интеграции разработанной системы в централизованные базы данных лечебных учреждений и медицинские архивы [4].

Заключение

Проведённое исследование подтвердило актуальность модульного подхода к построению системы поддержки принятия врачебных решений (СППВР) для анализа рентгеновских изображений позвоночника. Интеграция свёрточной нейронной сети YOLOv11 в качестве ядра модуля сегментации позволила полностью устранить этапы ручной разметки анатомических ориентиров и повысить воспроизводимость анализа. По результатам валидации точность локализации отдельных позвонков достигла 95% при уровне уверенности свыше 75 %, что превосходит показатели традиционных алгоритмов фильтрации и выделения признаков.

Разработанная архитектура — от предварительной обработки изображений до автоматической постановки диагноза и визуализации результатов — обеспечивает не только ускорение рутинного анализа снимков, но и соответствие требованиям медицинского документооборота. Полученные диагностические параметры (углы искривления, смещения и т. д.) автоматически передаются в модуль формирования заключения, что сокращает время подготовки отчёта врача и снижает влияние человеческого фактора.

Несмотря на высокие показатели, работа имеет ряд ограничений. Во-первых, обучающий датасет формировался на снимках одного учреждения, что может снижать обобщающую способность модели для редких патологий и нестандартных проекций. Во-вторых, текущая реализация ориентирована на 2D-снимки; перенос подхода на 3D-КТ или МРТ потребует дополнительного исследования.

В дальнейшем планируется:

- расширить выборку за счёт многопрофильных клиник для повышения устойчивости модели к различным условиям съёмки;
- интегрировать активное обучение, чтобы система могла дообучаться на новых данных без участия разработчиков;
- адаптировать модуль сегментации для трёхмерных томографических изображений и оценить пользу комбинации 2D– и 3D–признаков;
- реализовать прямое подключение к PACS-серверу с поддержкой DICOMweb для потоковой обработки исследований в реальном времени.

Таким образом, предложенное решение демонстрирует значительный потенциал для клинического применения, а также служит основой для дальнейших исследований в области медицинского компьютерного зрения и интеллектуальных систем поддержки врача.

Библиография

1. **Ahmed M. K., Havugimana F., Moinudin K. A.** MU-Net: Modified U-Net for Precise Localization and Segmentation of Lumbar-Spine Regions from Sagittal Views // In: Recent Advances in Soft Computing and Data Mining. – Springer, 2025.
2. **Guinebert S., Petit E., Bousson V., Bodard S.** Automatic semantic segmentation and detection of vertebrae and intervertebral discs by neural networks // *Intelligent Imaging*. – 2022.
3. **Kheirandish F.** Evaluation of U-Net model in the detection of cervical spine fractures: thesis. – Laurentian University, 2023. – 103 p.
4. **Nguyen H. Y.** Scoliosis Detection using Deep Neural Network: thesis. – Hanoi: University of Science and Technology of Hanoi, 2022. – 86 p.
5. **Yang R., Yu Y.** Artificial convolutional neural network in object detection and semantic segmentation for medical imaging analysis // *Frontiers in Oncology*. – 2021. – Vol. 11. – Article ID 638182.
6. **Yashwanth R., Gaurisankar S., Durga R.** Spine Vision X-Ray Image-based GUI Planning of Pedicle Screws Using Enhanced YOLOv5 for Vertebrae Segmentation // Cornell University preprint. – Ithaca, 2024. – P. 1–6.
7. **Мищенко И. И., Александров А. В., Шалухова М. А.** Способ интеллектуального распознавания Hip-Spine-синдрома // Интегрированные

модели и мягкие вычисления в искусственном интеллекте: сб. науч. тр. XII междунар. науч.-практ. конф. «ИММВ-2024». – 2024. – С. 245–254.

8. **Мищенко И. И., Мисник А. Е., Александров А. В.** Применение технологий компьютерного зрения и предварительной обработки изображений в системах поддержки принятия решений // Вестник Самарского государственного технического университета. – 2024. – № 4. – С. 6–26.

APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS FOR AUTOMATIC SPINE SEGMENTATION IN MEDICAL DECISION SUPPORT SYSTEMS

Ilya I. Mishchenko¹, Anton E. Misnik²

Belarusian-Russian University, Mogilev, Republic of Belarus

¹sombra74@yandex.by, ²anton@misnik.by

Annotation. This study presents an automatic spinal-segmentation module designed for a clinical decision-support system (CDSS). The core of the module is a YOLOv11 convolutional neural network, which replaces conventional filtering and equalization routines with deep-learning-based analysis. Trained on CVAT-annotated radiographs, the model achieves an average localization accuracy of 95% for the spine and individual vertebrae at confidence levels above 0.75. The CDSS follows a modular architecture comprising image pre-processing, segmentation, diagnostic-parameter computation and results visualization, enabling seamless integration with hospital information systems. The detected vertebral coordinates are fitted with a spline approximation of the spinal column, from which angular deviations are calculated to automatically identify deformities and generate preliminary assessments of scoliosis, kyphosis and hip-spine syndrome. Deploying the module shortens image-analysis time and improves diagnostic reproducibility, underscoring the promise of neural-network methods for medical computer-vision tasks.

Keywords. Computer vision, YOLOv11, spine segmentation, medical diagnostics, neural networks, decision support system.

* * *

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ДАННЫХ ДАТЧИКОВ ФАЛЬШПОЛА ДЛЯ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ

Дербина Кристина Андреевна^{1,2,а}, Симонов Роман Александрович^{2,3,б},
Глухих Дмитрий Игоревич^{2,в}

¹ООО «Тюмень-Софт», г. Тюмень, Россия,

²Тюменский государственный университет, г. Тюмень, Россия,

³ООО «Техноком», г. Тюмень, Россия

^аderk@tyumen-soft.ru, ^бsimonov@technocom.tech, ^вd.i.glukhikh@utmn.ru

Аннотация. В статье рассматривается подход к интеллектуальному анализу данных с датчиков фальшпола, направленный на повышение безопасности и минимизацию обработки и интерпретации данных. Для этого используются нейросети, которые позволяют автоматизировать мониторинг систем безопасности. Использование методов машинного обучения и анализа временных рядов позволяет обеспечить прогнозирование потенциальных чрезвычайных ситуаций, что способствует своевременному принятию решений и предотвращению несчастных случаев.

Ключевые слова. Анализ данных, машинное обучение, временные ряды, прогнозирование, промышленная безопасность.

Введение

Создание систем мониторинга на производственных предприятиях всегда было актуальным в свете факторов соблюдения безопасности, которые с каждым годом усиливаются законодательными инициативами. Актуальность этих систем также подтверждается постоянным стремлением исключить человеческий фактор, чтобы оптимизировать труд и повысить безопасность [1].

На сегодняшний день системы мониторинга производственных предприятий становятся все более высокотехнологичными. В них активно внедряются автоматизированные решения, которые помогают контролировать оптимальные параметры окружающей среды, обеспечить безопасность и создать комфортные усло-

вия труда. Кроме того, такие системы позволяют прогнозировать возможные поломки и предотвращать несчастные случаи.

В силу того, что автоматика занимает все больше места в системах анализа и мониторинга, роль человека в данной системе становится меньше с каждым днем. Исходя из этого, снижаются обязанности и требования к компетентности работника, а также все меньше требуются профессиональное образование и опыт по причине того, что все действия автоматизированная система выполняет за человека. Современные системы мониторинга генерируют огромные объемы данных с датчиков, но их прямая индикация (просто отображение значений) не дает понимания ситуации — человек не способен быстро анализировать тысячи параметров в реальном времени, а ручной поиск аномалий и прогнозирование становятся невозможными [2].

Поломки оборудования, возгорания, задымления можно предсказывать посредством системы анализа состояния через датчики. Это способствует предотвращению ущерба для предприятия, а также помогает принимать быстрые и верные решения. Такой подход также обеспечивает более высокий процент исключения несчастных случаев [3].

Перспективным направлением дальнейшего развития систем мониторинга заключается во внедрении методов машинного обучения для анализа больших данных для прогнозирования и раннего выявления потенциально опасных ситуаций, поддержки принятия решений в условиях неопределенности [4].

В результате возникает актуальная проблема и перспектива создания интеллектуальных систем поддержки принятия решений (СППР), которые способны путем сбора, анализа и обработки данных предсказывать чрезвычайные ситуации и давать пользователю рекомендации и порядок действий от экспертов, чтобы предотвратить несчастные случаи. Исследования в данной области уже сейчас демонстрируют свои возможности для решения отдельных задач, например, определять возгорания или затопления, классифицировать виды огня [1].

В данном исследовании будут рассмотрены процессы выявления нежелательной ситуации на основе датчиков фальшпола.

Рассматриваются датчики уровня углеводородных газов (метан, пропан, бутан), влажности, температуры. Индикация превышения порога не позволяет реализовать предиктивное обнаружение нежелательной ситуации (требующую вмешательства). Необходимо выявление определенных закономерностей во временной последовательности данных датчиков. Это позволит заблаговременно выявить нежелательную ситуацию и выдать рекомендации к действию.

Постановка задачи

Описание предметной области. Фальшпол представляет собой конструкцию, под которой располагаются коммуникации и оборудование, в том числе датчики. Датчиками предполагается непрерывно контролировать загазованность, температуру, влажность, вибрации и задымления. Сами датчики фиксируют значения без интерпретации в определенный момент времени. Благодаря внедрению интеллектуальной системы решаются задачи анализа взаимосвязей между параметрами датчиков, прогнозирования аварийных ситуаций, фильтрации ложных срабатываний.

Определение проблемы. Основная задача — сформировать обучающий набор данных, отражающий нюансы реальных условий эксплуатации. Выбрать и обучить модели искусственного интеллекта, способные выявлять закономерности во временной последовательности данных датчиков.

Традиционный подход к сбору данных для обучения моделей заключается в использовании готовых данных (в данном случае — временных рядов), собранных в процессе эксплуатации помещения с датчиками. Такой подход имеет следующие недостатки [1; 5]:

1. Зависимость данных от моделей датчиков. Не всегда готовые данные отвечают потребностям разрабатываемой системы по набору используемых датчиков. Разные модели могут иметь отличия в трендовых движениях показаний и разные пороговые значения.

2. Отсутствие готовых данных для некоторых кейсов для классификации. Для разрабатываемой системы может потребоваться

классификация ситуации, не представленной в открытых наборах данных.

Моделирование системы

Сбор и подготовка данных. Исходя из вышеперечисленных недостатков, было принято решение обучать модели на синтетическом датасете, сгенерированном на основе показаний целевых датчиков в лабораторных испытаниях [6]. Были выделены следующие переменные для генерации датасета:

- минимальные и максимальные показания каждого датчика для каждого сценария (тип нежелательной ситуации);
- размер временного окна значений для каждого сценария;
- количество генерируемых временных окон;
- шансы появления каждого из сценариев в сгенерированном датасете.

Генерация датасета происходит непосредственно в четыре этапа, каждый из которых отвечает за определенный уровень подготовки данных датасета.

Первый этап — формирование строки данных, которая содержит идентификатор времени, значения датчиков и тип сценария. На втором этапе происходит генерация нормального фрейма, то есть содержащий значения датчиков при нормальных состояниях и ситуациях, а также временные отметки, которые последовательно увеличиваются. Третий этап аналогично второму собирает показания датчиков, при этом выбирая тип аварийной ситуации, которая включает в себя: постепенное изменение значений датчиков к аварийным значениям, стабильное нахождение в аварийных показаниях, затем возвращение к нормальным значениям в случае предотвращения аварийной ситуации.

Финальная сборка датасета — программа поочередно перебирает временные окна и на каждом шаге случайным образом выбирает:

- сгенерировать нормальные данные;
- создать аварийный сценарий;
- результат записывается в итоговый файл.

Чтобы избежать жесткой привязки классифицируемых сценариев к конкретным численным значениям датчиков, которые могут изменяться со временем (например, из-за сезонных колебаний или переноса оборудования в другое помещение), используется специальный метод обработки данных. Входные показания датчиков преобразуются в нормализованный вектор признаков с помощью приведенных ниже формул. Такой подход позволяет модели оставаться устойчивой к изменению абсолютных значений датчиков, сохраняя при этом способность точно классифицировать сценарии.

Чтобы модель не зависела от абсолютных значений датчиков (которые могут меняться из-за сезонности, замены оборудования или других факторов), исходные данные преобразуются в нормированный вектор признаков.

1. Матрица данных

Матрица данных размером $T \times N$ рассчитывается по формуле (1):

$$\mathbf{X} \in \mathbb{R}^{T \times N}, \quad (1)$$

где T — длина окна (number of time steps), N — количество сенсоров.

2. Значение конкретного датчика в момент времени — отдельное измерение датчика.

3. Среднее значение датчика в окне

Показывает типичное значение датчика за последние T измерений. Помогает учесть «фоновый» уровень сигнала. Рассчитывается среднее значение для каждого сенсора из окна значений матрицы по формуле (2):

$$\mu_j = \frac{1}{T} \sum_{i=1}^T x_i^{(j)}, \quad j=1, 2, \dots, N, \quad (2)$$

где $x_i^{(j)}$ — значение конкретного датчика в момент времени, где j — сенсор, i — момент времени.

4. Стандартное отклонение датчика в окне

Показывает, насколько сильно «скачет» сигнал датчика. Большое отклонение → возможна аномалия или нестабильность.

Стандартное отклонение необходимо для расчета ошибки на каждом сенсоре, считается по формуле (3):

$$\sigma_j = \sqrt{\frac{1}{T} \sum_{i=1}^T (x_i^{(j)} - \mu_j)^2}, \quad j=1, 2, \dots, N. \quad (3)$$

5. Разница между первым и последним значением

Показывает, изменился ли сигнал за время окна (T шагов). Резкий рост/падение → возможен аварийный сценарий. Рассчитывается разница между первым и последним показанием с датчика по формуле (4):

$$\Delta_j = x_T^{(j)} - x_1^{(j)}, \quad j=1, 2, \dots, N. \quad (4)$$

6. Итоговый вектор признаков

Содержит все ключевые характеристики датчиков за окно T . Подается в модель машинного обучения для прогнозирования сценариев (норма/авария) [7]. Итоговый вектор для прогнозирования оценки считается по формуле (5):

$$\mathbf{f} = [\mu_1, \mu_2, \dots, \mu_N, \sigma_1, \sigma_2, \dots, \sigma_N, \Delta_1, \Delta_2, \dots, \Delta_N] \quad (5)$$

Модель анализирует не сами значения датчиков, а их статистические свойства. Это делает алгоритм устойчивым к смене оборудования, калибровке и внешним условиям.

Все формулы преобразуют «сырые» данные датчиков в универсальные признаки, которые:

- 1) не зависят от абсолютных значений (только от формы сигнала);
- 2) позволяют обнаруживать аномалии и тренды;
- 3) делают модель гибкой для разных условий работы.

Обоснование выбора языка моделирования. Для работы интеллектуальной системы поддержки принятия решений были использованы модели RandomForest и N-Beats. Первая модель представляет собой мета-оценщик, который работает на методе классификации деревьев решений на наборах данных и усредня-

ет для повышения точности. Для классификации сценариев была выбрана модель Random Forest. Ее преимущества [8]:

- 1) легковесность;
- 2) интерпретируемость;
- 3) устойчивость к шуму и переобучению;
- 4) обработка нелинейных зависимостей;
- 5) высокая точность и надежность.

N-BEATS — глубокая нейросеть прямого распространения, специально предназначенная для прогнозирования временных рядов. Её использование позволяет с высокой точностью предсказывать следующие n значений датчика для увеличения скорости реагирования системы на возникающий сценарий [9].

Для этих целей для каждого датчика в списке была обучена своя модель N-BEATS и встроена в механизм классификации: каждую итерацию перед классификацией T значений, из данных датчиков берётся $T/2$ значений, и моделями N-BEATS предсказываются $T/2$ значений (при $T \% 2 = 0$). Это позволяет в 2 раза увеличить скорость реагирования системы на разворачивающийся сценарий.

Построение модели. Размерность вектора признаков (на один временной интервал):

$$\text{Длина } v = 3 \times N, \quad (7)$$

где N — количество датчиков (в тестах использовалось $N = 5$), 3 — признака на каждый датчик: среднее значение (μ_j), стандартное отклонение (σ_j), разность крайних значений (Δj). Итого: каждый вектор v содержит 15 числовых признаков (для 5 датчиков).

Количество классов (сценариев): 4 класса (метки):

1. ОК (Норма)

Описание: Штатный режим работы системы. Все показания датчиков находятся в пределах нормальных значений.

Пример ситуации: Датчики фиксируют стандартные параметры окружающей среды без аномалий.

2. GAS_LEAK (Утечка газа)

Описание: Обнаружена утечка горючего газа. Показания газовых датчиков превышают допустимые нормы, но открытого огня нет.

Пример ситуации: Датчик метана показывает концентрацию 5 % LEL (Lower Explosive Limit).

3. GAS_FIRE (Утечка газа с возгоранием)

Описание: Утечка газа сопровождается локальным возгоранием. Характеризуется сочетанием аномальных показаний газовых датчиков и датчиков температуры/пламени.

Пример ситуации: Датчик метана показывает 15 % LEL, датчик температуры зафиксировал резкий рост до 200 °C.

4. OPEN_FIRE (Открытое возгорание)

Описание: Критическая ситуация с открытым пламенем. Температурные датчики и датчики пламени показывают экстремальные значения, при этом утечка газа может отсутствовать.

Пример ситуации: Датчик пламени сработал, температура превысила 500 °C, показания газовых датчиков в норме.

Размер датасета: 10,000 примеров (сбалансированных по классам).

Из них: 70 % — обучающая выборка, 20 % — валидационная, 10 % — тестовая.

На рис. 1 представлено временное окно для данных четырех датчиков: mq2 — датчик уровня углеводородов (ppm, 1 ppm = 0.0001 % концентрации газа в воздухе), mq7 — уровня метана (ppm), humidity — влажность (1 ед. = 0,1 % концентрации), temperature — температура (1 x 10 °C), class — ситуация.

Реализация системы. Финальная реализация системы отображена на диаграмме (рис. 2):

1. Считываются T последних записей из лога показаний датчиков (T = окно значений).

```
time,mq2,mq7,humidity,temperature,class
0,228,294,211,191,ok
0,229,291,220,198,ok
1,218,307,205,206,ok
2,227,281,200,203,ok
3,215,300,211,200,ok
4,215,311,211,191,ok
5,208,289,212,206,ok
6,208,308,214,201,ok
7,206,310,208,208,ok
8,220,315,219,201,ok
9,206,313,208,191,ok
10,213,283,220,197,ok
11,200,281,201,192,ok
12,226,284,202,192,ok
13,219,295,205,208,ok
14,218,316,201,190,ok
```

Рис. 1. Пример сгенерированного датасета




Рис. 2. UML диаграмма системы

2. Если включен N-BEATS:

– T последних записей передаются N-BEATS для прогнозирования.

– $T/2$ записей, спрогнозированных N-BEATS конкатенируются с $T/2$ последних записей из лога показаний датчиков и формируют собой обновленное окно значений [10].

3. Из окна значений вычисляется вектор, описанный в 2.1.

4. На основе вектора модель RandomForest вычисляет вероятность принадлежности вектора к каждому из классов.

5. Из матрицы вероятностей выбирается класс с наибольшим значением и сравнивается с заданным порогом уверенности (threshold), если вероятность больше порога – класс записывается в лог и выводится на клиенте, если меньше – в лог записывается класс “unexpected data”.

Анализ результатов. В ходе лабораторных испытаний системы были получены следующие результаты обучения моделей:

- RandomForest – точность 98 % на тестовой выборке;
- N-BEATS – точность 97 % на тестовой выборке;
- скорость определения системой класса сценария без N-BEATS – 6,24 секунд;
- скорость определения системой класса сценария с N-BEATS – 4,63 секунды;

– был сгенерирован синтетический датасет, отражающий различные сценарии работы датчиков фальшпола.

Заключение

В ходе данного исследования была успешно достигнута поставленная цель – сформирован обучающий набор данных, отражающий реальные условия эксплуатации датчиков, а также обучена модель машинного обучения на основе алгоритма Random Forest для выявления нежелательных ситуаций во временной последовательности данных датчиков. Полученные результаты подтверждают, что использование временных закономерностей в данных датчиков уровня углеводородных газов, влажности и температуры позволяет эффективно предсказывать потенциальные угрозы, что значительно улучшает возможности предиктивного обнаружения нежелательных ситуаций.

Исследование подтвердило эффективность подхода к анализу данных с датчиков фальшпола для поддержки принятия решений. Внедрение моделей помогло достичь высокой точности классификации и сократить время на принятие решений в потенциально опасных ситуациях.

Предложенный подход не только обеспечивает точное выявление опасных ситуаций, но и напрямую интегрируется с системой реагирования, автоматизируя критические действия. Например, при обнаружении утечки газа (GAS_LEAK) система самостоятельно активирует вентиляцию и блокирует подачу топлива, а в случае возгорания (OPEN_FIRE) – инициирует эвакуацию и вызывает экстренные службы, минимизируя зависимость от человеческого фактора. Такая связь между анализом данных и мгновенным выполнением протоколов безопасности существенно повышает надежность системы, превращая raw-данные датчиков в готовые решения для защиты людей и инфраструктуры.

Использование N-BEATS для прогнозирования временных рядов снизило время предотвращения возможного аварийного сценария с 6,24 до 4,63 секунд. В свою очередь RandomForest обе-

спечил надежность в обработке зависимостей для условий работы на реальном производстве. Комбинированный подход усилил не только точность, но и уменьшил время получения результатов.

Благодаря генерации синтетического датасета удалось научить систему распознавать несколько вариантов ситуаций, а учет стандартного отклонения и введение нормализации при генерации набора данных позволили повысить устойчивость системы к изменениям внешних условий, такие как сезонные колебания температуры воздуха.

Дальнейшие исследования могут быть направлены на тестирование системы в реальных промышленных условиях и расширение функционала за счет глубокого обучения и обработки естественного языка для автоматизации отчетности.

Библиография

1. **Islam, T., Rahman, H. A., Syrus, M. A.** Fire detection system with indoor localization using ZigBee based wireless sensor network // *Proceedings of the 2015 International Conference on Informatics, Electronics & Vision (ICIEV)*. — IEEE Press, Fukuoka, 2015. — P. 1–6.
2. **Onyinye Obioha Val, Oluwaseun Oladeji Olaniyi, Oluwatosin Selesi-Aina, Michael Olayinka Gbadebo, Titilayo Modupe Kolade et al.** Machine Learning-enabled Smart Sensors for Real-time Industrial Monitoring: Revolutionizing Predictive Analytics and Decision-making in Diverse Sector — 22 Nov 2024 — *Asian Journal of Research in Computer Science* — Vol. 17, Iss: 11, pp 92-113 — URL: <https://scispace.com/papers/machine-learning-enabled-smart-sensors-for-real-time-4idtynw77xha>.
3. **S. D. Prabu Ragavendiran, Deepak Shahakar, Deepika Kumari, Ajay Singh Yadav, P.M. Arthi, N Rajesha et al.** Predictive Maintenance of Electrical Machines using Machine Learning and Condition Monitoring Data — 09 May 2024 — URL: <https://scispace.com/papers/predictive-maintenance-of-electrical-machines-using-machine-4g7xxg2ae3>.
4. **Guruswamy TB, R. Manikandan et al.** AI-driven embedded systems for predictive maintenance in industrial IoT — 30 Sep 2020 — *World Journal Of Advanced Research and Reviews* — Vol. 7 — URL: <https://scispace.com/papers/ai-driven-embedded-systems-for-predictive-maintenance-in-5esv7zdh3vx0>
5. **P. Villoria Hernandez, I. Mariñas-Collado, A. Garcia Sipols, C. Simon de Blas, M. C. Rodriguez Sánchez** : Time series forecasting methods in emergency

contexts [Электронный ресурс]. — 2023. — URL: <https://www.nature.com/articles/s41598-023-42917-1> (дата обращения: 04.06.2025).

6. **Thanyathep Sasiaowapak, Siridech Boonsang, Santhad Chuwongin, Teerawat Tongloy, P. Lalitrojwong et al.** Generative AI for Industrial Applications: Synthetic Dataset — King Mongkut's Institute of Technology Ladkrabang — 26 Oct 2023 — pp 1-6 — URL: <https://scispace.com/papers/generative-ai-for-industrial-applications-synthetic-dataset-3z7k6on3lp>.

7. **Hyndman, R. J., Athanasopoulos, G.** *Forecasting: Principles and Practice*. — 3rd ed. — Melbourne: OTexts, 2021. — 380 p.

8. **Breiman, L.** Random Forests // *Machine Learning*. — 2001. — Vol. 45, No. 1. — P. 5–32.

9. **Oreshkin, B. N. et al.** N-BEATS: Neural Basis Expansion Analysis for Interpretable Time Series Forecasting // *arXiv preprint arXiv:1905.10437*. — 2019. — URL: <https://arxiv.org/abs/1905.10437>.

10. Pandas Development Team. *pandas: Powerful Data Structures for Data Analysis* [Электронный ресурс]. — 2023. — URL: <https://pandas.pydata.org/> (дата обращения: 04.06.2025).

INTELLIGENT ANALYSIS OF RAISED-FLOOR SENSOR DATA FOR DECISION SUPPORT

Kristina A. Derbina^{1,2}, Roman A. Simonov^{3,4}, Dmitry I. Glukhikh⁵

¹LLC Tyumen-Soft, Tyumen, Russia, ²Tyumen State University, Tyumen, Russia, ³LLC Technocom, Tyumen, Russia

^aderk@tyumen-soft.ru, ^bsimonov@technocom.tech, ^cd.i.glukhikh@utmn.ru

Abstract. This article examines an approach to intelligent analysis of raised-floor sensor data aimed at enhancing safety while minimizing data processing and interpretation. Neural networks are employed to automate the monitoring of safety systems. The use of machine learning methods and time-series analysis enables forecasting of potential emergencies, which facilitates timely decision-making and helps prevent accidents.

Keywords. Data analysis, machine learning, time series, forecasting, industrial safety.

* * *

ОЦЕНКА ВЛИЯНИЯ ФИЛЬТРАЦИИ ДАННЫХ НА КАЧЕСТВО ПАРАМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ МОДЕЛИ МЕТОДОМ ДИФФЕРЕНЦИАЛЬНОЙ ЭВОЛЮЦИИ

Георгиев Дмитрий Дмитриевич¹, Гебель Елена Сергеевна²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹dimadibro86@gmail.com, ²gebel_es@spbstu.ru

Аннотация. В процессе синтеза прогнозирующих моделей современных систем управления используются экспериментальные значения регулируемых величин и наблюдаемых возмущений от контрольно-измерительных приборов в распределенной АСУ ТП. Для технологических данных характерно наличие разброса вследствие погрешностей измерения и влияния внешних факторов. Качество экспериментального материала влияет на результаты решения задачи параметрической идентификации модели. Наличие корректной динамической модели объекта, учитывающей влияние основных возмущающих воздействий, является необходимым условием для построения предиктивного управления. Исследование направлено на оценку влияния различных способов фильтрации исходных данных на результаты параметрической идентификации модели технологического объекта в форме передаточной функции.

Ключевые слова. Передаточная функция; предобработка данных; идентификация модели; синтез.

Введение

В условиях стремительного развития информационных технологий и внедрения на производстве концепций Индустрии 4.0 применение методов интеллектуального управления технологическими процессами становится критически важной задачей для обеспечения технологического лидерства нефтеперерабатывающих предприятий Российской Федерации. Совершенствование

систем управления технологическими процессами предполагает переход к моделям прогнозирующего управления (МРС), эффективность которых зависит от точности математического описания статистики и динамики процессов. Накопленный инженерный опыт реализации систем автоматического управления показывает, что использование математических моделей на основе линейных (линеаризованных) неоднородных дифференциальных уравнений не выше второго порядка обеспечивает требуемое качество регулирования большинства технологических объектов, в частности, трубчатой печи, рассматриваемой в работе. В то время, как параметрический синтез (идентификация) параметров передаточной функции (коэффициентов дифференциального уравнения) на основе экспериментальных значений регулируемых величин и наблюдаемых возмущений от контрольно-измерительных приборов оказывается весьма сложной математической задачей.

Рекуррентные алгоритмы метода наименьших квадратов, расширенного и обобщенного метода наименьших квадратов, метода максимального подобия, метода инструментальных переменных и других для решения поставленной задачи сталкиваются с проблемами наличия случайных сигналов и застревания в локальных минимумах. Метод дифференциальной эволюции обладает лучшей устойчивостью к шуму, эффективно находит глобальные экстремумы целевой функции, что позволяет найти оптимальные значения параметров модели, которая наиболее точно описывает динамику реального объекта [1, 2]. Известно, что эффективность и точность решения оптимизационной задачи параметрической идентификации передаточной функции зависит от качества исходных данных, в качестве которых используются исторические значения технологических параметров. Фильтрация является одним из способов борьбы с зашумленностью данных, устранения выбросов и пропущенных значений.

Целью настоящего исследования является анализ результатов параметрической идентификации передаточной функции

методом дифференциальной эволюции на предобработанных различными методами фильтрации данных. В работе приняты предположения о линейности и стационарности исследуемого динамического объекта. Расход сырья FC-1081.PV на выходе трубчатой печи регулируется путем изменения давления топлива PC-0053.SV.

Применяемые подходы

В работе рассматриваются следующие виды фильтрации:

- **Экспоненциальный фильтр** предназначен для сглаживания временных рядов с помощью экспоненциального усреднения, при котором новые значения получают больший вес по сравнению со старыми, что позволяет уменьшить влияние случайных шумов и сделать тренды более выраженными. Метод особенно эффективен при наличии высокочастотного шума, который возникает из-за небольших колебаний в измерениях, например, вызванных неточностью датчиков или случайными помехами.

- **Фильтр скользящего среднего** заменяет пропущенные значения в данных на среднее арифметическое в определённом окне, эффективен при устранении случайных всплесков и шумов, равномерно распределённых по временной шкале. Используется для сглаживания данных, но может ослаблять резкие изменения сигнала, что нежелательно для систем, где наблюдаются быстрые переходные процессы.

- **Фильтр Калмана** является адаптивным и динамическим фильтром, прогнозирует истинное состояние системы на основе её предыдущего состояния и новых измерений. Эффективен в условиях, когда данные содержат как случайные шумы, так и систематические искажения [3].

- **Медианный фильтр** заменяет каждую точку сигнала на медианное значение из заданного окна используется в случае наличия выбросов, возникающих из-за кратковременных помех или неисправностей датчиков. В отличие от скользящего среднего, медианный фильтр лучше сохраняет резкие переходы в данных, что

делает его подходящим для обработки сигналов с импульсными помехами [4].

- **Гауссов фильтр** выполняет сглаживание данных, используя веса, распределённые по нормальному закону, что позволяет удалять случайные шумы без значительного искажения трендов. Подходит для обработки сигналов, содержащих небольшие колебания с нормальным распределением, такие как температуры или концентрации веществ в потоке [5].

- **Фильтр выбросов** выявляет аномальные значения сигнала, выходящие за предельно допустимые границы, что возникает вследствие неисправности датчиков, ошибок операторов или внезапных изменений технологического процесса. Выбросы заменяются на средние значения соседних точек, тем самым делая данные более гладкими и непрерывными.

Полученные результаты

На рис. 1 показаны следующие диаграммы: входное ступенчатое изменение входного сигнала — давление на входе в печь (PC-0053.SV), экспериментальные данные отклика системы управления — расход на выходе аппарата (FC-1081.PV), а также линия тренда («Модель_1») в соответствии с синтезированной на исходном неотфильтрованном наборе данных моделью объекта.




Рис. 1. Модель на неотфильтрованном выходе

Методом дифференциальной эволюции получены следующие параметры передаточной функция рассматриваемого контура регулирования:

$$W(s) = \frac{3,68 * e^{-0,454s}}{37,529s + 1}. \quad (1)$$

Значение среднеквадратического отклонения (СКО) модельных значений выходного сигнала от исходных составило 2,115. Результаты оценки влияния различных способов фильтрации данных на качество параметрического синтеза проведена серия вычислительных экспериментов представлены в табл. 1.

Как следует из результатов в табл. 1, точность аппроксимации моделей, полученных на предобработанных численных данных, оказалась более чем на 50 % выше, достигнув минимального зна-

Таблица 3

**Результаты параметрической идентификации
на предобработанных данных**

Вид фильтра	Передаточная функция контура регулирования	Значение СКО
Экспоненциальный фильтр	$W(s) = \frac{2,857 * e^{-10,12s}}{28,32s + 1}$	1,43
Фильтр скользящего среднего	$W(s) = \frac{3,14 * e^{-0,126s}}{29s + 1}$	1,657
Фильтр Калмана	$W(s) = \frac{2,84 * e^{-9,343s}}{27,012s + 1}$	1,294
Медианный фильтр	$W(s) = \frac{3,393 * e^{-0,125s}}{35,28s + 1}$	1,752
Гауссов фильтр	$W(s) = \frac{3,187 * e^{-0,786s}}{32,26s + 1}$	1,616
Фильтр выбросов	$W(s) = \frac{3,662 * e^{-0,105s}}{39,94s + 1}$	2,08




Рис. 2. Сравнение результатов параметрического синтеза моделей по переходным характеристикам

чения 1,294. На рис. 2 показаны диаграммы переходных характеристик исходной модели на непредобработанных данных «Модель_1» и модели, синтезированной после применения фильтра Калмана – «Модель_2».

Как следует из рис. 2, в начале рассматриваемого временного интервала поведение моделей совпадает, что объясняется отсутствием достаточной накопленной статистики. Отличия в динамическом поведении наблюдаются при резком снижении входного сигнала. Шум в исходном усиливается. Колебательный характер выходного сигнала на участке после 13:00 аппроксимируется монотонной кривой в связи со структурой принятой математической модели. Однако среднее значение исходной диаграммы оказывается ближе к кривой «Модель_2».

Заключение

В результате проведенного исследования установлено, что фильтрация исходных технологических данных для решения задачи параметрического синтеза математической модели контура регулирования положительно влияет на качество результатов. Параметры передаточных функций, рассчитанные методом диф-

ференциальной эволюции, менялись в широки пределах, за исключением коэффициента преобразования. Динамика контура регулирования описывалась математической моделью первого порядка, что является приемлемым для инженерных приложений. В этой связи колебательный характер выходного сигнала на участке после 13:00 (рис. 2) на модели был сглажен. Фильтр Калмана среди прочих рассмотренных способов предобработки численных данных оказался наиболее эффективным, СКО уменьшилось на 38,8% по сравнению с исходным. Таким образом, параметры модели точнее отражают динамику системы.

Библиография

1. **Пантелеев А. В., Дмитраков И. Ф.** Применение метода дифференциальной эволюции и его модификаций в задаче поиска оптимального управления дискретными детерминированными системами // Научный вестник МГТУ ГА. 2011. № 169. URL: <https://cyberleninka.ru/article/n/primeneniye-metoda-differentsialnoy-evolyutsii-i-ego-modifikatsiy-v-zadache-poiska-optimalnogo-upravleniya-diskretnymi> (дата обращения: 06.02.2025).
2. **Ходашинский И. А., Дудин П. А.** Идентификация нечетких систем на основе метода дифференциальной эволюции // Доклады ТУСУР. 2011. №1 (23). URL: <https://cyberleninka.ru/article/n/identifikatsiya-nechetkikh-sistem-na-osnove-metoda-differentsialnoy-evolyutsii> (дата обращения: 06.02.2025).
3. **Бобырь, М. В., Булатников В. А.** Моделирование нечеткого фильтра и фильтра Калмана для обработки входного сигнала // Информационные технологии и нанотехнологии (ИТНТ-2020) : Сборник трудов по материалам VI Международной конференции и молодежной школы. В 4-х томах, Самара, 26–29 мая 2020 года / Под редакцией В.А. Фурсова. Т 4. — Самара: Самарский национальный исследовательский университет имени академика С.П. Королева, 2020. — С. 825–830.
4. **Семенов, И. В.** Особенности использования медианных фильтров в системах управления // Гирокоспия и навигация. — 2006. — № 2(53). — С. 104.
5. **Сатаев, В. В.** Проектирование гауссовых фильтров в структуре гидроакустического канала // Труды XXVII научной конференции по радиофизике, Нижний Новгород, 15–25 мая 2023 года. — Нижний Новгород: Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского, 2023. — С. 238–241.

EVALUATION OF THE EFFECT OF DATA FILTERING ON THE QUALITY OF PARAMETRIC IDENTIFICATION OF THE MODEL BY THE METHOD OF DIFFERENTIAL EVOLUTION

Dmitry D. Georgiev¹, Elena S. Gebel²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹dimadibro86@gmail.com, ²gebel_es@spbstu.ru

Abstract. Experimental values of controlled quantities and observed disturbances from control and measuring devices in a distributed automated process control system are used in the process of synthesizing predictive models of modern control systems. The technological data obtained is characterized by the presence of a spread due to measurement errors and the influence of external factors. The quality of the experimental material affects the results of solving the problem of parametric identification of the control object model. The presence of a correct dynamic model of a technological facility that takes into account the influence of the main disturbing influences is a prerequisite for building predictive control. The study is aimed at assessing the impact of various methods of filtering source data on the results of parametric identification of a technological object model in the form of a transfer function.

Keywords. Transfer function; data preprocessing; model identification; synthesis.

* * *

Секция 4.

**«ПРОМЫШЛЕННАЯ
КИБЕРБЕЗОПАСНОСТЬ»**

УДК 004.056
doi:10.18720/SPBPU/2/id25-554

**КИБЕРУСТОЙЧИВОСТЬ
ЦИФРОВОЙ ЭЛЕКТРОПОДСТАНЦИИ**

Гавва Георгий Дмитриевич¹, Калинин Максим Олегович²

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹gavva.gd@edu.spbstu.ru, ²max@ibks.spbstu.ru

Аннотация. В статье рассматривается проблема обеспечения киберустойчивости цифровой электроподстанции, уязвимой к кибератакам, способным вызвать отключения электроэнергии и экономические потери. Предлагается инновационный адаптивный механизм управления безопасностью внутренней сетью связанных устройств цифровой электроподстанции на основе стохастического самообучающегося автомата с переменной структурой и линейной тактикой, который управляет правилами взаимодействия узлами в условиях воздействия кибератак.

Ключевые слова. Цифровая подстанция, локальная вычислительная сеть, киберустойчивость, самообучающийся автомат.

Введение

Цифровые электроподстанции (ЦПС) играют важную роль в современных энергетических системах. Они используются для управления и контроля электрической энергией, обеспечивают автоматизированное функционирование и мониторинг электри-

ческих сетей в реальном времени, улучшая надежность энергосистемы. ЦПС также позволяют операторам энергосистемы быстро реагировать на возникающие аварийные ситуации и проводить удаленное управление и диагностику оборудования. К другим преимуществам ЦПС можно отнести эффективность и экономию затрат за счет высокого уровня автоматизации и минимизации потерь энергии, гибкость и масштабируемость благодаря адаптивности к новым технологиям и требованиям; и экологичность, которая подразумевает интеграцию возобновляемых источников энергии.

Широкий функционал и быстрое распространение ЦПС, интеграция таких систем в критическую информационную инфраструктуру (КИИ) Российской Федерации и не до конца решенные на сегодняшний день вопросы стандартизации ЦПС [1] спровоцировали проблему киберугроз, направленных на нарушение функционирования ЦПС и построенных на их основе энергосистем, и определили необходимость и актуальность решения задачи поддержания кибербезопасности и киберустойчивости ЦПС [2].

Известные в настоящее время методы поддержания киберустойчивости ЦПС базируются на обнаружении аномалий [3-5] и обеспечении безопасности сетевых протоколов управления в киберсреде ЦПС [6-8]. Однако данные решения не подразумевают адаптацию в случае уже произошедшего инцидента. Ключевым при решении задачи управления киберустойчивостью ЦПС является разработка адаптивного решения, реализующего быстрое реагирование на инциденты и позволяющего повысить надежность и защищенность ЦПС. Данное решение должно удовлетворять ряду требований:

- 1) функционирование в режиме реального времени в связи с чувствительностью среды ЦПС к временным задержкам;
- 2) способность к адаптации к разным типам кибератак на внутреннюю сеть связанных устройств ЦПС;
- 3) возможность внедрения в ЦПС без конфликтов с уже функционирующими в ней технологиями;

4) невысокая вычислительная сложность реализуемого метода, поскольку он должен быть внедрен в маломощные устройства ЦПС.

Авторами обоснован выбор самообучающейся конечно-автоматной модели для реализации управления киберустойчивостью ЦПС. Проанализированы разновидности самообучающихся автоматов и характеристики среды, благодаря чему определены тип, тактика и рабочие параметры разработанного самообучающегося автомата — стохастический автомат с линейной тактикой. Для построенного автомата выполнена оптимизация его рабочей конфигурации с учетом условий функционирования ЦПС. Оценка, проведенная для базового стохастического автомата с линейной тактикой, показала эффективность данной модели.

Анализ подходов к обеспечению киберустойчивости ЦПС

При разработке решения проанализированы следующие подходы к построению модели управления сетью устройств ЦПС, а также определены их сильные и слабые стороны (табл. 1):

1) подход на основе модели байесовской сети доверия (БСД) [9]: используется модель доверия — если узел ведет себя честно, вероятность доверия увеличивается, а если поступает подозрительная информация (например, происходит атака), доверие снижается. Этот механизм позволяет перенаправлять информационные потоки по каналам с большим уровнем доверия и перестраивать БСД, изолируя подозрительные узлы;

Таблица 1

Анализ подходов к обеспечению киберустойчивости ЦПС

Критерий сравнения \ Базовая модель	Модель БСД	Модель сетевой игры	Самообучающийся автомат
Динамическая адаптивность	+	—	+
Вычислительная сложность	Высокая	Низкая	Низкая
Масштабируемость	+	+	+

2) подход на базе модели сетевой игры: моделируя характеристики и закономерности поведения злоумышленников в течение жизненного цикла атаки, подходы на основе теории игр могут облегчить формулирование оптимальных стратегий смягчения, которые минимизируют потери от атак, учитывая при этом сопутствующие затраты и реализуя сбалансированный компромисс [10–12];

3) подход на базе модели самообучающегося конечного автомата: самообучающийся автомат решает задачу обеспечения киберустойчивости сети благодаря своей способности адаптироваться к динамическим условиям, обучаться на основе обратной связи и принимать решения для оптимизации работы системы [13, 14]. Его ключевая характеристика — умение обучаться на основе поощрений и штрафов — позволяет эффективно решать задачи, связанные с обнаружением угроз, выбором оптимальных стратегий защиты и распределением ресурсов в условиях ограниченности информации.

Наиболее перспективным направлением представляется математическая модель самообучающегося автомата. Уникальность данной модели определяется несколькими факторами: адаптивность, простота и эффективность, устойчивость к динамическим угрозам.

Модель самообучающегося автомата

В области теории управления самообучающийся автомат определен как кортеж из пяти элементов $\langle A, B, Q, F(\cdot, \cdot), G(\cdot) \rangle$, где $A = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$ — множество выходных координат, или действий. $\alpha(t)$ — действие, выбранное автоматом в текущий момент времени t ; $B = \{\beta_1, \beta_2, \dots, \beta_m\}$ — множество входных координат для автомата. $\beta(t)$ — входная координата в текущий момент времени t . Множество B может быть конечным или бесконечным.

В нашем случае рассматривается вариант $m = 2$, то есть $B = \{0, 1\}$, где $\beta = 0$ — событие, за которое автомат поощряется, а $\beta = 1$ — событие, за которое назначается штраф. $Q = \{q_1, q_2, \dots, q_s\}$ — множе-

тво конечных состояний. $q(t)$ обозначает состояние автомата в текущий момент времени t . $F(\cdot, \cdot) : Q \times B \rightarrow Q$ – преобразование состояния и входных координат в текущий момент времени t так, чтобы $q(t+1) = F(q(t), \beta(t))$. F называется функцией перехода, которая определяет состояние автомата в следующий момент времени $t+1$. $G(\cdot)$ – преобразование $G : Q \rightarrow A$, именуемое функцией выхода. В зависимости от состояния в конкретный момент времени, функция G определяет выходную координату автомата в тот момент времени, когда $\alpha(t) = G(q(t))$.

Для построенного автомата определены действия-реакции устройств ЦПС $D = \{d_1 - \text{игнорирование}, d_2 - \text{блокировка соединения}, d_3 - \text{пересылка трафика на другое ИЭУ того же типа}\}$. Данное множество реакций обусловлено функциональными воз-




Рис. 1. Зависимости средних штрафов M автомата от его инерционности (глубины лепестков) Q и показателя изменчивости среды δ

Конфигурация разработанного самообучающегося автомата

Параметр	Значение	Описание
Изменчивость среды	$\delta \rightarrow 0$	Под изменчивостью среды δ понимается количество сетевых поведенческих сценариев (например: трафик без сбоев, различный аварийный трафик, различный вредоносный трафик и т. д.), которое может реализовать интеллектуальное электронное устройство (далее ИЭУ) ЦПС за период времени, деленное на количество трафика, производимое ИЭУ за этот период времени. Вредоносное или аварийное поведение нетипично для среды ЦПС, поэтому полагается, что $\delta \rightarrow 0$.
Глубина лепестков	$Q = 5$	При наименьшем показателе изменчивости среды δ оптимальное значение $Q_{\text{опт}}$ глубины лепестка равно 5 или 6, при этом разница значения M (математического ожидания штрафа) пренебрежимо мала, поэтому дополнительное (шестое) состояние избыточно.
Детерминированный / стохастический	Стохастический по F	Среда ЦПС в условиях атакующих воздействий является стохастической нестационарной средой, что исключает использование детерминированной модели автомата. В стохастическом автомате по F переход автомата из одного состояния в другое происходит с определенной долей вероятности, что обеспечивает возможность самообучения автомата. Если бы автомат был стохастическим еще и по G , это определило бы необходимость задания дополнительных ограничений на действия для каждого состояния автомата. Хранение и применение этих правил потребует больше вычислительных ресурсов.
Фиксированная / переменная структура	Переменная структура	Пересчет вероятности переходов автомата из одного состояния в другие и считается его способностью к обучению.

Окончание табл. 2

Параметр	Значение	Описание
Использование линейной тактики	Автомат с линейной тактикой	Использование линейной тактики обусловлено особенностями среды ЦПС и возможными действиями от ИЭУ. Если не использовать линейную тактику, автомат будет стремиться к случайному поведению в контексте решаемой задачи в среде ЦПС.
Схема обучения	Схема «Поощрение-штраф»	Пересчёт вероятностей перехода по стрелкам-поощрениям не производится. Пересчёт вероятностей перехода по стрелкам-штрафам производится и при положительной, и при отрицательной реакции детектора на действие автомата. В качестве g_j и h_j (функций корректировки вероятностных переходов поощрения и штрафа) используются ступенчатые функции (p_{ij} – вероятность перехода автомата из состояния i в состояние j): $g_j = \begin{cases} 0,1; & 1 \geq p_{ij} > 0,1 \\ \frac{p_{ij}}{2}; & 0,1 \geq p_{ij} > 0 \\ 0; & p_{ij} \leq 0 \end{cases} \quad h_j = \begin{cases} 0,2; & 1 \geq p_{ij} \geq 0,7 \\ 0,15 & 0,7 \geq p_{ij} \geq 0,4 \\ 0,1; & 0,4 \geq p_{ij} \geq 0,1 \\ \frac{p_{ij}}{2}; & 0,1 \geq p_{ij} > 0 \\ 0; & p_{ij} \leq 0 \end{cases}$

можностями ИЭУ в среде ЦПС. Множество реакций D допускает модификацию и расширение. Действие d_1 является фактически отсутствием какого-либо ответного действия на инцидент. Для реализации действия d_2 ИЭУ может обновлять свои настройки подписки (например, игнорировать сообщения с определённого MAC-адреса или GOOSE ID), что фактически приводит к блокировке трафика от вредоносного ИЭУ. Эти изменения могут происходить в реальном времени, без участия человека. Для реализации действия d_3 на коммутатор, подключенный к ИЭУ, это устройство создает и отправляет правило, содержащее MAC-адрес и команду изменения ACL для перенаправления трафика, кроме

того, если устройство поддерживает технологию резервирования, оно автоматически переключает свои подписки на резервное устройство.

Оптимальная конфигурация автомата, используемого для обеспечения киберустойчивости ЦПС, представлена в табл. 2. Для выявления данной конфигурации использовался график зависимости уровня целесообразности от изменчивости δ нестационарной среды и глубины лепестков Q [15].

Стохастический САПС с линейной тактикой [3, 5] (по количеству действий и глубине лепестков) избыточен по количеству состояний для действий d_2 и d_3 . Действие d_2 представляет собой блокировку соединения. Устройство, обнаружившее вредоносное воздействие от другого ИЭУ может перестать принимать от него пакеты, для данного действия достаточно одного состояния. Перенаправление трафика (d_3) возможно на устройства того же типа, что и задетектировано вредоносное, обслуживающее другие ИЭУ, или на резервное устройство. Для данного действия достаточно трёх состояний.

При положительной реакции среды на активное действие автомата (d_2 или d_3) целесообразно с точки зрения устойчивости системы перенаправлять поощрение на лепесток d_1 в самое не глубокое его состояние, поскольку в случае последующего штрафа автомат сразу перейдёт к активным действиям, а в случае дальнейших поощрений уйдёт в глубинную лепестка d_1 . Таким образом, итоговая модель для ЦПС показана на рис. 2.




Рис. 2. Модель САПС без избыточных состояний в момент начала функционирования ИЭУ

Экспериментальные результаты

В качестве экспериментального стенда используется Python-модель на базе программной библиотеки NetworkX, моделирующей графовые зависимости в топологии сети. Схема ЦПС, моделируемая с помощью данной библиотеки, представлена на рис. 3 (на графе топологии сети синим цветом показаны устройства уровня станции/подстанции, зеленым — коммутационные аппараты шин станции/подстанции и процесса, оранжевым — узлы ЦПС на уровне присоединения, желтым — устройства на уровне процесса).

Определено, какого уровня целесообразности может достичь автомат в случае изменчивости δ нестационарной среды и какова при этом его оптимальная глубина лепестков Q .

В результате экспериментов показано, что при самообучении модель справляется с атакой «черная дыра» на 60 % быстрее, чем до обучения, а с FDI-атакой в 2 раза быстрее, чем до обучения. Полученные результаты подтверждают работоспособность и эф-




Рис. 3. Схема сети устройств ЦПС, построенная с помощью библиотеки NetworkX

фективность стохастического самообучающегося автомата с линейной тактикой в качестве инструмента киберустойчивости ЦПС.

Заключение

Созданная модель стохастического самообучающегося автомата с переменной структурой и линейной тактикой представляет собой механизм адаптивного управления информационными потоками в сети ЦПС. В процессе дообучения автомат справляется с повторным инцидентом быстрее, что подтверждает высокий уровень устойчивости среды в условиях воздействия кибератак. Кроме того, способность перестроения автоматной модели управления демонстрирует большой потенциал в противодействии неизвестным кибератакам в среде ЦПС за счет возможности постоянного дообучения модели управления.

Библиография

1. Нормы технологического проектирования подстанций переменного тока с высшим напряжением 35-750 кВ. // Россети URL: <https://www.rosseti.ru/upload/iblock/d3c/xnpk3cmk5y7pr49xbgp90k40bgrtsr94.pdf?ysclid=lvz3cke1f8271863163>.
2. Ярошенко А. Цифровые подстанции: выгоды и риски / Ярошенко А. // «Электротехнический рынок». — 2023. — № 2 (110).
3. Kwon Y. J. et al. Behavior analysis and anomaly detection for a digital substation on cyber-physical system / Electronics. — 2019. — Т. 8. — № 3. — С. 326.
4. Network System Management: End-System-Related International Electrotechnical Commission (IEC) 62351-7 Object Definitions. / EPRI Report.
5. Kwon Y. J. et al. A behavior-based intrusion detection technique for smart grid infrastructure / 2015 IEEE Eindhoven PowerTech. — IEEE, 2015. — С. 1–6.
6. Johnson D., Menezes A., Vanstone S. The elliptic curve digital signature algorithm (ECDSA) / International journal of information security. — 2001. — Т. 1. — С. 36–63.
7. Kush N. S. et al. Poisoned GOOSE: Exploiting the GOOSE protocol / Proceedings of the Twelfth Australasian Information Security Conference (AISC 2014) [Conferences in Research and Practice in Information Technology, Volume 149]. — Australian Computer Society, 2014. — С. 17–22.
8. Hussain S. et al. A novel methodology to validate cyberattacks and evaluate their impact on power systems using real time digital simulation / 2021 IEEE texas power and energy conference (TPEC). — IEEE, 2021. — С. 1–6.

9. Карпычев В. Ю., Сычев В. М. Применение байесовых сетей в задачах анализа внутренних угроз информационной безопасности / Вестник ВИ МВД России. — 2015. — № 1.

10. Tan J. et al. A survey: When moving target defense meets game theory / Computer Science Review. — 2023. — Т. 48. — С. 100544.

11. Wang Z. et al. Optimal DoS attack strategy for cyber-physical systems: A Stackelberg game-theoretical approach / Information Sciences. — 2023. — Т. 642. — С. 119134.

12. Lalropuia K. C., Gupta V. Modeling cyber-physical attacks based on stochastic game and Markov processes / Reliability Engineering & System Safety. — 2019. — Т. 181. — С. 28–37.

13. Dong M. et al. Learning automaton-based energy-efficient and fault-tolerant topology evolution algorithm for underwater acoustic sensor network / Journal of Network and Computer Applications. — 2023. — Т. 217. — С. 103690.

14. Черняк Л. Машина Цетлина — конкурент нейронным сетям? / Открытые системы. СУБД. — 2018. — №3.

15. Лекция 42. Обучение автоматов // stratum.ac.ru URL: <https://stratum.ac.ru/education/textbooks/modelir/lection42.html?ysclid=mbqsavekr91568416954>.

CYBER RESILIENCE OF THE ELECTRIC DIGITAL SUBSTATION

Georgij D. Gavva¹, Maxim O. Kalinin²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹gavva.gd@edu.spbstu.ru, ²max@ibks.spbstu.ru

Abstract. The paper considers the problem of ensuring cyber resilience of a digital electric substation vulnerable to cyber threats that can cause power outages and economic risks. An innovative adaptive mechanism for managing the security of an internal network of connected devices of a digital electric substation has been proposed based on a stochastic self-learning automaton with a variable structure and linear tactics, which controls the rules of interaction between nodes under the influence of cyber attacks.

Keywords. Digital substation, local area network, cyber resilience, self-learning automaton.

* * *

УДК 330.1

doi:10.18720/SPBPU/2/id25-555

ОБЪЯСНИМАЯ RUNTIME-ДЕТЕКЦИЯ НАРУШЕНИЙ API-КОНТРАКТОВ В МИКРОСЕРВИСАХ НА ОСНОВЕ T-GNN

Арсеньев Дмитрий Германович^{1,а}, Баскаков Дмитрий Евгеньевич^{2,б}

¹Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия;

²Общество с ограниченной ответственностью «Газинформсервис»,
Санкт-Петербург, Россия

^аvicerektor.int@spbstu.ru, ^бBaskakov-D@gaz-is.ru

Аннотация. Статья предлагает новый метод обнаружения нарушений API-контрактов между микросервисами прямо в процессе их работы (runtime). В основе подхода лежит использование временной графовой нейронной сети (англ. Temporal Graph Neural Network, T-GNN), которая анализирует структуру вызовов и временные зависимости в потоках взаимодействующих сервисов. Ключевое преимущество метода — его объяснимость: модель не только выявляет аномалии (нарушения контрактов), но и указывает на конкретные сервисы и типы нарушений, облегчая диагностику проблем. Это позволяет эффективно контролировать сложные распределенные системы и повышать их надежность.

Ключевые слова. Микросервисы, API-контракты, нарушение контрактов, runtime-детекция, временная графовая нейронная сеть (T-GNN), объяснимый ИИ (XAI), мониторинг, распределенные системы, аномалии взаимодействия.

Введение

Архитектура микросервисов стала стандартом для построения сложных распределенных систем, обеспечивая гибкость и масштабируемость решений [1, с. 3]. Критически важным для надежной работы таких систем является соблюдение API-контрактов, регламентирующих взаимодействие между сервисами [2, с. 45]. Нарушения этих контрактов (несвоевременные вызовы, несоответ-

ствие данных, пропущенные операции) — частая причина сбоев, трудно диагностируемая в runtime-среде [3, с. 1998].

Существующие методы контроля (статические контракты, централизованный мониторинг логов/трассировок) недостаточны для оперативного обнаружения сложных нарушений в динамически меняющихся взаимодействиях [3, с. 1998; 4]. Авторами предлагается метод объяснимой runtime-детекции нарушений API-контрактов на основе T-GNN [5, с. 1]. T-GNN анализирует динамический граф вызовов, выявляя структурные и временные аномалии. Далее системой детекции создаются объяснимые результаты (указание на сервис-нарушитель и тип нарушения), что значительно упрощает диагностику.

Обзор литературы

Проблема обеспечения надежности взаимодействия микросервисов через API-контракты является критической для современных распределенных систем. Классические работы Newman [1, с. 78–82] и Richardson [2, с. 45–50, 120–125] закладывают основу понимания архитектуры микросервисов, подчеркивая, что явные и строго соблюдаемые контракты — ключ к устойчивости микросервисных систем. Авторы детально описывают типичные паттерны нарушений, такие как несовместимость форматов данных (Schema Drift), несоблюдение ожидаемых кодов ответа и нарушение последовательности вызовов, которые сложно контролировать в динамической среде [1, с. 80; 2, с. 123]. Традиционные подходы к обеспечению соблюдения контрактов, включая статическую спецификацию (например, OpenAPI [3, разд. 3.8.1]) и централизованный анализ логов/трассировок, демонстрируют существенные ограничения при детекции runtime-нарушений, особенно связанных с временными зависимостями и частичной деградацией.

Как показано в исследовании Chen et al. [4, с. 1998–2000], эти методы плохо масштабируются, страдают от высокой задержки обнаружения и не обеспечивают достаточной контекстной информации для локализации корневой причины сложных инцидентов

в графе вызовов. Экспоненциальный рост сложности диагностики сбоев в микросервисных средах из-за их распределенности, слабой связанности и динамичности указывает на необходимость разработки новых методов анализа телеметрии, способных выявлять не только явные ошибки, но и скрытые нарушения контрактов между сервисами в реальном времени.

В качестве перспективной технологической основы для решения задачи объяснимой детекции runtime-нарушений контрактов выделяются T-GNN. Работа Rossi et al. [5, с. 1–3] демонстрирует их способность эффективно моделировать структурно-временную эволюцию динамических графов, улавливая сложные зависимости и аномалии в последовательностях взаимодействий, что потенциально позволяет преодолеть ограничения существующих методов мониторинга микросервисов и детектирования их неисправности [4, с. 2000].

Методология

В работе предложена методология runtime-детекции нарушений API-контрактов в микросервисных архитектурах, основанная на интеграции T-GNN и формальных спецификаций контрактов. Методология включает четыре этапа: формализацию контрактов, построение динамических графов, обучение T-GNN-модели и интерпретацию результатов детекции.

На первом этапе контракты микросервисов формализуются с использованием линейной темпоральной логики (англ. Linear Temporal Logic, LTL), которая позволяет задавать допустимые последовательности вызовов API, ограничения на параметры и временные зависимости между событиями. Формальная спецификация служит эталоном для сравнения с наблюдаемым поведением системы. Для описания структуры данных и типов сообщений применяются схемы OpenAPI, интегрированные в LTL-спецификации [6, с. 305].

На втором этапе собираются трассы исполнения (англ. execution traces) из микросервисов с помощью sidecar-mode, например, Istio,

и преобразуются в динамические графы. Узлы графа соответствуют сервисам, а рёбра — вызовам API с атрибутами: тип запроса (GET/POST), параметры, коды ответа и временные метки [5, с. 6]. Такое представление позволяет учитывать как структурные, так и темпоральные аспекты взаимодействия.

Для анализа графов используется T-GNN-архитектура, сочетающая графовые свёртки, например, GraphSAGE, с рекуррентными слоями GRU. Модель обучается на графах, соответствующих корректному исполнению контрактов, и предсказывает ожидаемые состояния узлов и рёбер. Отклонения от прогноза интерпретируются как потенциальные нарушения [7, с. 4768]. Для повышения интерпретируемости реализован attention-механизм, выделяющий ключевые элементы графа и временные точки, влияющие на решение модели.

Предложенная методология обеспечивает:

1. Формальное моделирование контрактов через LTL и OpenAPI.
2. Темпоральное представление взаимодействий в виде динамических графов.
3. Обнаружение аномалий с помощью T-GNN с объяснимостью через attention.
4. Интеграцию в DevOps-процессы для раннего выявления ошибок интеграции микросервисов.

Предлагаемая методология решает задачу оперативного выявления и интерпретации нарушений API-контрактов в микросервисных средах посредством трех ключевых инноваций:

1. **Динамическое моделирование графа сервисов с семантикой контрактов.** Взаимодействия формализуются как временной ориентированный граф

$$G(t) = (V, E, \tau, C),$$

где $V = \omega_i$ — узлы графа (микросервисы), $E \subseteq V \times V$ — ребра графа (вызовы микросервисов), $\tau : E \rightarrow R^+$ — временные метки вызовов, а $C : E \rightarrow \Phi$ — функции контрактов (схемы запросов/ответов, SLA) [8].

2. T-GNN с двунаправленной временной агрегацией. Для анализа динамики графа применяется модифицированная архитектура T-GNN:

$$h_v^{(t)} = T - GNN_{\Theta} (h_u^{(t-1)}, \oplus_{u \in N_n} \psi(h_u^{(t-1)}, C(u, v))), \quad (1)$$

где $h_v^{(t)}$ — эмбединг узла v в момент t , $\oplus_{u \in N_n}$ — дифференцируемый оператор агрегации (mean/max pooling), $\psi(\cdot)$ — функция трансформации признаков соседей, $C(u, v)$ — векторное представление контракта.

3. Объяснимый механизм детекции аномалий. Нарушения детектируются через линейный Attention-Based Anomaly Scoring:

$$s_e = \sigma \left(W_a \times \left[h_u^{(t)} \times \left\| h_v^{(t)} \right\| \times \Delta_t \right] \right), \quad (2)$$

где σ — сигмоида и Δ_t — отклонение времени ответа.

Для объяснения результатов используется специализированная техника, визуализирующая критический путь нарушения, тип аномалии (временная/структурная/семантическая) и вероятностную оценку серьезности.

Выводы и дальнейшие перспективы исследования

Предложенный метод объяснимой runtime-детекции нарушений API-контрактов на основе T-GNN должен демонстрировать высокую эффективность, безусловно, за счет ключевого своего преимущества — интерпретируемость результатов, которое можеткратно сократить время диагностики за счет идентификации типа аномалии (временная/семантическая/структурная) и критического пути, то есть места или источника ее нахождения.

Перспективы дальнейших исследований, по нашему мнению, возможно сосредоточить в направлении Lightweight-T-GNN (LT-GNN) для edge-устройств с оптимизацией ресурсов или федеративное детектирование аномалий с применением LT-GNN. А с учетом сложности верификации современных КФРС нам видится

крайне полезным с инженерной точки зрения переход от верификации ПО к детекции потенциальных аномалий ПО посредством механизмов, описанных выше.

Заключение

Предложен инновационный метод обнаружения нарушений API-контрактов в микросервисах на основе T-GNN, обеспечивающий высокоточную интерпретируемую детекцию в реальном времени. Ключевое преимущество решения — сочетание оперативного анализа динамики взаимодействий сервисов с возможностью объяснения причин нарушений, что радикально сокращает время диагностики сбоев. Метод демонстрирует потенциальное значительное превосходство над традиционными подходами мониторинга как по точности обнаружения аномалий, так и по скорости реакции в силу детектирования узла (сервиса) с потенциальным аномальным поведением.

Решение открывает перспективы для создания самоадаптирующихся микросервисных систем с непрерывной верификацией или детекцией контрактов, а дальнейшие исследования авторов будут направлены на оптимизацию решения для распределенных edge-сред (LT-GNN) и предиктивное предотвращение сбоев.

Библиография

1. **Newman S.** Building Microservices. — Sebastopol: O'Reilly Media, 2015. — 281 p.
2. **Richardson C.** Microservices patterns: with examples in Java. — Shelter Island: Manning Publications, 2018. — 520 p.
3. OpenAPI Initiative. OpenAPI Specification v3.1.0 [Электронный ресурс]. — URL: <https://spec.openapis.org/oas/v3.1.0> (дата обращения: 22.06.2025).
4. **Chen B., Wang Q., Wang B.** et al. Detecting Anomalies in Microservice System Execution Traces Using a Deep Learning Model // IEEE Transactions on Network and Service Management. — 2021. — Vol. 18, № 2. — P. 1997–2011.
5. **Rossi E., Chamberlain B., Frasca F.** et al. Temporal Graph Networks for Deep Learning on Dynamic Graphs // Proceedings of the 37th International

Conference on Machine Learning (ICML 2020). — PMLR 119, 2020. — P. 1–10. — arXiv:2006.10637.

6. **Baier, C.** Principles of model checking / C. Baier, J.-P. Katoen. — Cambridge, MA: MIT Press, 2008. — 975 p.

7. **Lundberg, S. M.** A unified approach to interpreting model predictions / S. M. Lundberg, S.-I. Lee // Advances in Neural Information Processing Systems. — 2017. — Vol. 30. — P. 4765–4774.

8. <https://qodex.ai/blog/api-compliance-testing>

9. **Zhou X., Peng X., Xie T.** et al. Fault Analysis and Debugging for Microservice Systems // Foundations and Trends in Software Engineering. — 2021. — Vol. 5, № 2. — P. 103–298.

EXPLAINABLE RUNTIME DETECTION OF API CONTRACT VIOLATIONS IN MICROSERVICES BASED ON T-GNN

Dmitry Germanovich Arseniev^{1,a}, Dmitry Evgenievich Baskakov^{2,6}

¹Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia;

²Limited Liability Company «Gazinformservice», Saint Petersburg, Russia

^avicerecort.int@spbstu.ru, ⁶baskakov-D@gaz-is.ru

Abstract. The article proposes a new method for detecting API contract violations between microservices directly at runtime. The approach is based on the use of the Temporal Graph Neural Network (TGNN), which analyzes the structure of calls and time dependencies in the flows of interacting services. The key advantage of the method is its explainability: the model not only identifies anomalies (contract violations), but also points to specific services and types of violations, facilitating problem diagnostics. This allows for effective monitoring of complex distributed systems and increasing their reliability.

Keywords. Microservices, API contracts, contract violation, runtime detection, Temporal Graph Neural Networks (TGNN), Explainable AI (XAI), monitoring, distributed systems, service interaction, anomaly detection.

* * *

ОБЕСПЕЧЕНИЕ ЦЕЛОСТНОСТИ ГЛОБАЛЬНОЙ МОДЕЛИ ФЕДЕРАТИВНОГО МАШИННОГО ОБУЧЕНИЯ В КРУПНЫХ ПРОМЫШЛЕННЫХ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИИ БЛОКЧЕЙН

Охлопков Никита Михайлович¹, Калинин Максим Олегович²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹ohlopkov_nm@spbstu.ru, ²max@ibks.spbstu.ru

Аннотация. В статье рассматривается проблема нарушения целостности глобальной модели федеративного машинного обучения в промышленных интеллектуальных системах. Представлен блокчейн-метод защиты, обеспечивающий контроль достоверности параметров локальных моделей и устойчивость к подмене меток и зашумлению весов за счет использования многоуровневой валидации, репутационного консенсуса и мажоритарного голосования. Экспериментально показано сохранение точности прогнозов защищаемой модели интеллекта выше 83% при компрометации до 50 % узлов-клиентов федеративного машинного обучения.

Ключевые слова. Безопасная агрегация, блокчейн, валидация весов, промышленный искусственный интеллект, репутационный консенсус, федеративное машинное обучение, целостность модели.

Введение

Современные промышленные предприятия активно внедряют системы промышленного искусственного интеллекта (ПИИ) для мониторинга оборудования, прогнозного обслуживания, оптимизации логистики и управления качеством. Распределенное федеративное машинное обучение (ФМО) позволяет обучать модели на критически важных данных крупных систем, включая различные цеха, филиалы, отделы, АСУ ТП и киберфизические системы, без их централизованной передачи, сохраняя конфиденциальность технологических секретов.

На рис. 1 представлена централизованная система ФМО, в которой существует агрегирующий сервер, собирающий параметры всех локальных моделей ФМО, обученных клиентами, и на их основе формирует глобальную модель ФМО. При наличии n клиентов каждый из них обучает модель на собственных данных, после чего передает параметры обученной локальной модели на центральный сервер для агрегации. Сервер агрегирует поступившие параметры, формирует обновленную глобальную модель ФМО и возвращает ее обратно клиентам. Этот процесс повторяется итеративно до тех пор, пока не будет достигнута требуемая точность глобальной модели ФМО.




Рис. 1. Схема ФМО

Децентрализованная природа ФМО создает риски целенаправленных атак на целостность моделей: злоумышленники могут менять метки в данных, зашумлять параметры моделей или внедрять зловредные весовые коэффициенты в алгоритмы управления. Для обеспечения устойчивого функционирования промышленных АСУ ТП и роботизированных комплексов необходимы методы, гарантирующие достоверность глобальной модели ФМО даже при частичной компрометации узлов.

Анализ существующих методов защиты моделей ФМО и их ограничения

В промышленных ФМО-средах выделяются два класса атак:

1. Атаки на данные сенсоров и метки дефектов: подмена меток [1, 2] брака при визуальном контроле изделий; внедрение шумов в измерения датчиков тока, давления и температуры.

2. Атаки на параметры алгоритмов управления: зашумление весов нейросетей предсказания отказов, целенаправленная манипуляция критическими весами в системах управления [3].

Такие атаки могут привести к незапланированным простоям линий, снижению качества продукции и аварийным остановкам.

Современные исследования [4, 5] рассматривают применение технологии блокчейн в системах ФМО с целью повышения эффективности распределения вычислительных ресурсов между участниками. В них представлены успешные кейсы интеграции блокчейна в системы ФМО. Однако известные решения не раскрывают весь потенциал использования блокчейна в ФМО: в них отсутствует сравнение с альтернативными механизмами обеспечения безопасности, а также не приведены результаты противодействия широкому спектру атак, включая манипуляции параметрами модели и подмену меток.

Медианная [6] и усеченная [7] агрегация защищают от экстремальных обновлений, но снижают точность модели, что критично для тонкого управления технологическими процессами. Статистические методы обнаружения выбросов [8] и графовые подхо-

ды доверия [9] требуют значительных вычислительных ресурсов, недоступных на периферии (edge-устройствах на производстве). Методы удаления нейронов [10] и сериализации данных [11] мало адаптированы под реальное время обработки в АСУ ТП.

Разработанный метод защиты на основе технологии блокчейн

Разработан многоуровневый метод, учитывающий специфику ПИИ. Формальное описание разработанного метода:

1. Инициализация системы. Пусть $(K + 1) \in \mathbb{N}$ – количество майнеров ФМО, т. е. существует $M = \{m_0, m_1, \dots, m_K\}$ – множество майнеров ФМО. Пусть $(N + 1) \in \mathbb{N}$ – количество участников ФМО, т. е. существует $D = \{d_0, d_1, \dots, d_N\}$ – множество клиентов ФМО. Существует отображение $f: D \rightarrow M$, ставящее в соответствие каждому устройству своего майнера, т. е. $f(d_i) = m_j, i \leq N, j \leq K$. Блокчейн инициализируется с корневым блоком.

2. Локальное обучение на устройствах. Каждое устройство d_i обучает локальную модель на своих данных. В результате получается множество весов: $W = \{w_0, w_1, \dots, w_N\}$.

3. Передача весов w_i от каждого участника d_i соответствующим майнерам m_j .

4. Трансляция весов между майнерами. Каждый майнер m_j отправляет набор весов W_j от соответствующих клиентов другим майнерам. В результате у каждого майнера имеются веса от всех участников ФМО.

5. Валидация весов. Каждый майнер m_j выполняет два вида проверок: проверка с помощью теневой модели и анализ распределения весов.

6. Трансляция результатов валидации между майнерами. В итоге каждый майнер m_j получает информацию о независимых результатах валидации других майнеров.

7. Обработка результатов валидации. Применяется механизм мажоритарного голосования для определения подозрительных устройств. Устройство-клиент ФМО считается подозрительным, если его отметило большинство майнеров. Подозрительные

устройства исключаются из системы ФМО на некоторое время. Порог (1) для определения подозрительных устройств при мажоритарном голосовании:

$$Threshold = \left\lceil \frac{K}{2} \right\rceil + 1 \quad (1)$$

8. Майнеры, чьи результаты сильно отличаются от большинства, также исключаются из системы. Условие для исключения майнера выражается формулой (2):

$$|S_{miner} \Delta S_{majority}| > \varepsilon \quad (2)$$

где S_{miner} – множество подозрительных устройств, определенных майнером; $S_{majority}$ – множество подозрительных устройств, определенных большинством майнеров; Δ – симметрическая разность множеств; ε – пороговое значение различия.

9. Создание блоков-кандидатов. Каждый майнер m_j создает блок-кандидата $Block_j$.

10. Механизм консенсуса. Формула (3) показывает, что выбор победившего блока основывается на репутации майнеров и количестве валидированных весов:

$$W_{block_candidate} = e^{R*RF} * e^{V*VWF}, \quad (3)$$

где R – репутация майнера, создавшего блок-кандидата; RF – фактор влияния репутации; V – количество валидированных весов; VWF – фактор влияния количества валидированных весов; $RF, VWF \in [0, 1]$ и $RF + VWF = 1$.

Блок-победитель $Block_{winner}$ выбирается случайным образом с вероятностью, пропорциональной весу, согласно формуле (4):

$$P(Block_i) = \frac{W_i}{\sum_{j=1}^n W_j}, \quad (4)$$

где W_i – вес i -го блока-кандидата; n – общее количество блоков.

11. Обновление блокчейна. Победивший блок $Block_{winner}$ добавляется в блокчейн. Репутация майнера, создавшего победивший блок, увеличивается.

12. Перераспределение устройств. После каждой итерации происходит перераспределение устройств между майнерами на основе их репутации. Майнер с наивысшей репутацией получает дополнительное устройство от майнера с наименьшей репутацией.

13. Агрегация моделей. Веса W_{winner_block} из победившего блока используются для обновления глобальной модели.

Далее процесс повторяется, начиная с шага 2, для следующей итерации ФМО.

Такой подход позволяет сохранять историческую неизменяемость операций обучения и адаптивно реагировать на промышленные инциденты.

Экспериментальное исследование разработанного метода

На примерах атак зашумления параметров модели и подмены меток экспериментально оценена эффективность применения разработанного метода защиты. В табл. 1 представлены результаты оценки точности глобальных моделей без защиты $T_{БЗ}$ и с защитой с помощью построенного метода $T_{ПМ}$.

Таблица 1

Результаты оценки точности глобальных моделей при атаках на целостность

Атака	Доля атакующих, %	$T_{БЗ}$, %	$T_{ПМ}$, %
Подмена меток	0	83,06	
	10	83,09	82,83
	50	38,24	81,97
	60	12,60	77,50
Зашумление параметров	0	83,06	
	10	72,81	82,48
	50	57,20	82,36
	60	50,00	82,10

Полученные результаты продемонстрировали, что при атаке подмены меток точность глобальной модели сохранялась на уровне 83 % при до 50 % скомпрометированных клиентов; при атаке зашумления параметров модель сохраняла стабильную точность вне зависимости от доли атакующих.

Заключение

Разработанный метод обеспечивает надежность и безопасность крупных распределенных промышленных ФМО-систем за счет прозрачности и неизменяемости блокчейн-журнала; многоуровневой валидации, адаптированной под KPI производства; репутационного консенсуса. Решение соответствует задачам по внедрению прорывных технологий в автоматизацию, роботизацию и управление объектами на производстве.

Библиография

1. **Shafahi A.** et al. Poison frogs! targeted clean-label poisoning attacks on neural networks //Advances in neural information processing systems. — 2018. — Т. 31.
2. **Jagielski M.** et al. Manipulating machine learning: Poisoning attacks and countermeasures for regression learning //2018 IEEE symposium on security and privacy (SP). — IEEE, 2018. — С. 19–35.
3. **Lu S., Li R., Liu W.** FedDAA: a robust federated learning framework to protect privacy and defend against adversarial attack //Frontiers of Computer Science. — 2024. — Т. 18. — № 2. — С. 182307.
4. **Huang L.** et al. Hierarchical Service Composition via Blockchain-enabled Federated Learning //Data Science and Engineering. — 2024. — С. 1–15.
5. **Liu J.** et al. Enhancing trust and privacy in distributed networks: a comprehensive survey on blockchain-based federated learning //Knowledge and Information Systems. — 2024. — Т. 66. — № 8. — С. 4377–4403.
6. **Pillutla K., Kakade S. M., Harchaoui Z.** Robust aggregation for federated learning //IEEE Transactions on Signal Processing. — 2022. — Т. 70. — С. 1142–1154.
7. **Yin D.** et al. Byzantine-robust distributed learning: Towards optimal statistical rates //International conference on machine learning. — Pmlr, 2018. — С. 5650–5659.

8. **Shen S., Tople S., Saxena P.** Auror: Defending against poisoning attacks in collaborative deep learning systems //Proceedings of the 32nd annual conference on computer security applications. — 2016. — С. 508–519.

9. **Zhang C.** et al. Anomaly detection and defense techniques in federated learning: a comprehensive review //Artificial Intelligence Review. — 2024. — Т. 57. — № 6. — С. 1–34.

10. **Wu C.** et al. Mitigating backdoor attacks in federated learning //arXiv preprint arXiv:2011.01767. — 2020.

11. **Cretu G. F.** et al. Casting out demons: Sanitizing training data for anomaly sensors //2008 IEEE Symposium on Security and Privacy (sp 2008). — IEEE, 2008. — С. 81–95.

PROVIDING THE INTEGRITY OF THE GLOBAL FEDERATED MACHINE LEARNING MODEL IN LARGE INDUSTRIAL INTELLECTUAL SYSTEMS USING BLOCKCHAIN TECHNOLOGY

Nikita M. Ohlopkov¹, Maxim O. Kalinin²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹ohlopkov_nm@spbstu.ru, ²max@ibks.spbstu.ru

Abstract. The paper addresses the integrity challenges of global models in federated machine learning within industrial intellectual environments. There is presented a blockchain-based protection method that ensures control of the reliability of the parameters of local models and resistance to label switching and weight noise. In comparison with well-known solutions, multilevel validation, reputational consensus and a mechanism of majority voting are proposed. Experimental results demonstrate that, even with up to 50% of compromised nodes, the global model maintains accuracy more than 83%.

Keywords. Secure aggregation, blockchain, weight validation, industrial artificial intelligence, reputational consensus, federated machine learning, model integrity.

* * *

ПРИМЕНЕНИЕ ВРЕМЕННОЙ ЛОГИКИ ПРИ ВЕРИФИКАЦИИ ПРОЦЕССОВ ОБРАБОТКИ И ХРАНЕНИЯ БОЛЬШИХ ДАННЫХ

Подоров Андрей Алексеевич¹, Полтавцева Мария Анатольевна²

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹podorov_aa@spbstu.ru, ²poltavtseva@ibks.spbstu.ru

Аннотация. Тема работы — применение временной логики для верификации систем обработки и хранения больших данных, с целью выявления ошибок и несоответствий в процессах обработки и хранения данных в распределённых системах больших данных. Объектом исследования является распределённая система обработки и хранения больших данных. В работе выполнен анализ архитектур и подходов к обеспечению безопасности в распределённых системах, обоснован выбор логики линейного времени и инструмента TLA⁺, предложена формализация модели жизненного цикла обработки больших данных. Разработан тестовый стенд, выполняющий автоматическую генерацию спецификаций на языке TLA⁺.

Ключевые слова. Большие данные, информационная безопасность, формальная верификация, процессы обработки данных, жизненный цикл данных, TLA⁺.

Введение

Безопасность в распределённых системах обработки и хранения больших данных сопряжена с особыми трудностями, связанными с их масштабом, динамичностью и архитектурной сложностью [1]. Данные в таких системах поступают из множества разнородных и часто нестабильных источников — от пользовательских и серверных событий до результатов внешних API-запросов и телеметрии. Они имеют разные форматы, частоту обновления, уровень доверия и требуют многократной трансформации в процессе обработ-

ки [2]. Все это происходит в условиях масштабируемых архитектур, где отдельные компоненты работают независимо, а контроль за состоянием данных и правами доступа рассредоточен по всей инфраструктуре [3].

Постановка задачи

Гетерогенные системы больших данных. Системы больших данных работают в условиях постоянной изменчивости: данные поступают непрерывно, появляются новые источники, изменяются форматы, обновляется логика обработки. Это требует высокой степени адаптивности не только от архитектуры, но и от всех инструментов безопасности. Другая сложность — многостадийный жизненный цикл данных. Один и тот же объект может пройти через фильтрацию, агрегацию, обогащение, анонимизацию, анализ и хранение в архиве. На каждом этапе требуется разный уровень контроля, соответствующий не только техническому, но и правовому статусу данных [4].

Типичная распределённая система больших данных состоит из трёх слоёв [5]:

1. Физический уровень — распределённые файловые системы, вычислительные кластеры, облачные ресурсы, обеспечивающие хранение и обработку больших объёмов данных с отказоустойчивостью.

2. Логический уровень — инструменты транспортировки данных (Kafka, NiFi), обработки (Spark, Flink), хранения (HDFS, MongoDB, Cassandra), аналитики (Presto, ClickHouse).

3. Концептуальный уровень — модели потоков данных, схемы трансформации, интерфейсы API, политики доступа и правила маршрутизации информации.

Эти уровни создают модульную архитектуру, где каждая подсистема может масштабироваться независимо и обновляться без остановки всей системы. Однако это же и порождает фрагментацию логики, затрудняет унификацию контроля доступа и требует согласования форматов и политик на каждом этапе обработки.

Определение проблемы. В условиях высокой динамики особую важность приобретает не только управление доступом [6], но и верификация процессов обработки информации в условиях динамической архитектуры. Нарушения происходят, в том числе, когда система допускает доступ без учёта стадии обработки или контекста. Кроме того, данные могут перемещаться между хранилищами и средами исполнения, теряя при этом информацию о своих атрибутах безопасности. Ситуацию усложняет технологическая гетерогенность: внутри одной платформы могут использоваться различные СУБД, форматы хранения, инструменты потоковой обработки и аналитики. Это приводит к фрагментации политик безопасности, трудностям в унификации управления и невозможности централизованной проверки соблюдения заданных правил [7].

Такая постановка ведёт к необходимости применения формальных подходов, позволяющих не только описывать, но и проверять соблюдение политик безопасности с учётом временных и контекстных зависимостей. В этой связи особый интерес представляют методы, основанные на временной логике, которая может служить инструментом описания и анализа поведения системы во времени.

Верификация процессов в системах больших данных

Обоснование выбора метода верификации. Для наглядного сравнения методов формальной верификации, основанных на временных логиках, в табл. 1 приведены их ключевые характеристики. Учитывались такие параметры, как применяемый математический аппарат, возможность моделирования параллельных процессов, поддержка сложных структур, способы представления данных и пригодность для распределённых систем.

В результате анализа выбрана верификация с использованием TLA+.

Предложенный способ верификации. Процессы обработки и хранения больших данных представлены в виде ориентированного графа, где каждый узел соответствует определённому состоянию

Таблица 1

Сравнение формальных методов верификации

Критерий	Подходы к верификации формальных моделей		
	TLA+	PROMELA	Petri Nets
Математический аппарат	TLA	LTL	CTL
Возможность моделирования параллельных процессов	Да	Да	Да
Поддержка произвольно-сложных структур	Да	Нет	Нет
Представление данных	Множества	Си – подобные типы данных	Фиксированный набор типов
Средства проверки состояний использует распределённые системы	Да	Да	Да
Подходит для распределённых и параллельных систем	Да	Да	Нет

данных, а рёбра графа задают допустимые переходы между состояниями и отражают типичную последовательность этапов обработки. Этот граф можно интерпретировать как структуру Крипке $M = (S, S_0, R, L)$: множество состояний S – узлы графа; начальное состояние $s_0 \in S$ – первый узел S_0 ; отношение переходов $R \subseteq S \times S$ – направленные рёбра; функция разметки $L: S \rightarrow 2AP$ – описывает свойства каждого состояния, тип данных и стадию обработки. На практике структура может содержать циклы (например, переобработка данных), развилки слияния и терминальные состояния (архив, удаление). Это отражает реалистичную модель обработки данных в системах больших данных.

Верификация корректности обработки и хранения данных выполняется методом Model Checking на базе языка спецификаций TLA+ и инструмента TLC. В рамках этой процедуры мы описываем переменные модели – список всех состояний (узлов); допу-

стимых переходов между ними и логических свойств состояний; начальное состояние — узел S_0 ; действия системы — допустимые переходы по рёбрам; инварианты — логические свойства, которые должны сохраняться во всех траекториях обработки. Теорема корректности — утверждение, что указанные инварианты выполняются во всех возможных путях. В качестве инвариантов задаются такие требования, как, например:

— Если персональные данные были экспортированы или предоставлен к ним доступ, то до этого они обязательно прошли анонимизацию и проверку.

— Если данные SCADA были визуализированы, то на предыдущих этапах они обязательно были агрегированы и валидированы.

Все инварианты объединяются в логическое выражение *Invariants*, описывающее совокупное условие корректности, включающее требования к последовательности этапов обработки различных типов данных. Теорема корректности проверяет выполнение этих инвариантов во всех допустимых сценариях обработки. Она записывается с использованием композиции операторов. Это позволяет учесть начальную инициализацию системы или подготовительные этапы обработки, после которых система должна войти в безопасное устойчивое состояние и оставаться в нём.

Такая формулировка отражает реалистичный сценарий эксплуатации распределённых систем, где допустимы переходные состояния, но после их завершения необходимо гарантировать соблюдение всех требований безопасности.

Если верификация проходит успешно, это означает, что заданная структура обработки и хранения данных соответствует заданным нормативным требованиям безопасности. Если же обнаруживается нарушение хотя бы одного инварианта, средство верификации укажет на соответствующий путь, в котором возникает ошибка — что позволяет:

- выявить некорректные переходы;
- уточнить этапы обработки, в которых возникает нарушение;
- скорректировать граф переходов или свойства узлов, устранив проблему до запуска системы.

Таким образом, предложенный способ обеспечивает строгую проверку допустимости всех возможных путей обработки информации, позволяя верифицировать архитектуру до её внедрения. Это повышает доверие к системе и исключает ошибки, которые могли бы проявиться только при длительной эксплуатации.

Заключение

В работе был представлен способ формальной верификации корректности процессов обработки и хранения данных в системах больших данных. Для этого модель обработки представлена в виде ориентированного графа, интерпретируемого как структура Крипке, где состояния отражают этапы жизненного цикла данных, а переходы между ними — допустимые изменения состояния. На этой основе с использованием языка спецификаций TLA+ и метода Model Checking формализованы инварианты, отражающие требования к последовательности обработки различных типов данных. Теорема корректности, записанная с применением темпорального оператора, позволяет убедиться, что во всех сценариях развития событий система достигает устойчивого состояния, в котором соблюдены все требования безопасности. Такой подход даёт возможность выявить нарушения логики обработки до развёртывания системы, тем самым снижая риски утечек, потери данных и несоблюдения нормативных требований.

Исследование выполнено за счет гранта Российского научного фонда № 23-11-20003, <https://rscf.ru/project/23-11-20003/>, грант Санкт-Петербургского научного фонда (Соглашение № 23-11-20003 о предоставлении регионального гранта)

Библиография

1. Anjum N., Latif Z., Chen H. Security and privacy of industrial big data: Motivation, opportunities, and challenges // *Journal of Network and Computer Applications*. — 2025. — С. 104130.
2. Osborn S. L., Servos D., Shermin M. Issues in access control and privacy for big data // *Granular, Fuzzy, and Soft Computing*. — New York, NY: Springer US, 2023. — С. 615–623.

3. **Demchenko Y.** et al. Big security for big data: Addressing security challenges for the big data infrastructure //Workshop on secure data management. — Cham : Springer International Publishing, 2013. — С. 76–94.

4. **Broeders D.** et al. Big Data and security policies: Towards a framework for regulating the phases of analytics and use of Big Data //Computer Law & Security Review. — 2017. — Т. 33. — №. 3. — С. 309–323.

5. **Imran S.** et al. Big data analytics in healthcare— A systematic literature review and roadmap for practical implementation //IEEE/CAA Journal of Automatica Sinica. — 2020. — Т. 8. — № 1. — С. 1–22.

6. **Bhandari R.** et al. Big data security—challenges and recommendations // International Journal of Computer Sciences and Engineering. — 2016. — Т. 4. — № 1. — С. 93–98.

7. **Katal A., Wazid M., Goudar R. H.** Big data: issues, challenges, tools and good practices //2013 Sixth international conference on contemporary computing (IC3). — IEEE, 2013. — С. 404–409.

USING OF TEMPORAL LOGIC IN THE PROCESSES OF BIG DATA PROCESSING AND STORING VERIFYING

Andrey A. Podorov¹, Maria A. Poltavtseva²

Peter the Great St. Petersburg Polytechnic University,
St. Petersburg, Russia

¹podorov_aa@spbstu.ru, ²poltavtseva@ibks.spbstu.ru

Abstract. The topic of the paper is the application of temporal logic for verification of big data processing and storage systems, in order to identify errors and inconsistencies in the processes of data processing and storage in distributed big data systems. The object of the research is a distributed big data processing and storage system. The paper analyzes architectures and approaches to ensuring security in distributed systems, justifies the choice of linear time logic and the TLA+ tool, and formalizes the life cycle model for big data processing. A test bench has been developed that performs automatic specification generation in the TLA+ language.

Keywords. Big data, information security, formal verification, data processing, data lifecycle, TLA+.

* * *

УДК 004.056

doi:10.18720/SPBPU/2/id25-558

ПРИМЕНЕНИЕ МОДЕЛИ ДОВЕРИЯ ДЛЯ ПОВЫШЕНИЯ ЗАЩИЩЕННОСТИ РАСПРЕДЕЛЕННОГО РЕЕСТРА В ИНФОРМАЦИОННЫХ СИСТЕМАХ УМНОГО ГОРОДА

Васильев Олег Сергеевич¹, Крудышев Василий Михайлович²

Санкт-Петербургский политехнический университет
Петра Великого, Санкт-Петербург, Россия

¹vasiliev.os@edu.spbstu.ru, ²krundyshev_vm@spbstu.ru

Аннотация. В статье исследуется проблема обеспечения безопасности систем распределенного реестра в цифровых инфраструктурах умного города. Для таких подсистем умного города характерны следующие свойства: размытость информационного периметра, самоорганизация и мобильность узлов сети, а также низкий объем вычислительных ресурсов и дискового пространства у большинства устройств. В таких условиях защиты систем распределенного реестра от атак, связанных с подделкой транзакций, предлагается применить ориентированный ациклический граф, дополненный моделью доверия.

Ключевые слова. Система распределенного реестра, ориентированный ациклический граф, модель доверия, умный город.

Введение

За последние несколько лет можно наблюдать значительный рост количества успешных проектов, реализующих концепцию умного города. Одним из драйверов цифровизации мегаполисов является технология распределенного реестра, предполагающая децентрализованное хранение данных [1, 2]. Однако, при использовании данной технологии в самоорганизующихся и неоднородных инфраструктурах умного города возникает проблема, связанная с риском подделки транзакций. Для защиты систем распределенного реестра ряд исследователей предлагает использовать ориентированный ациклический граф (DAG), в основе которого

лежат события, содержащие полезную нагрузку, метку времени, подпись создателя и ссылки на два родительских события: на самого себя и на другой узел, полученное при синхронизации [3]. В классической реализации каждому узлу при голосовании приписывается одинаковая весовая доля (stake), и каждое событие вносит равный вклад в достижение консенсуса. Такая система успешно противостоит искажению истории в условиях, когда в сети злоумышленников не более 30% от общего количества узлов. При этом такой подход не учитывает, как часто узел вел себя корректно или некорректно в прошлых синхронизациях. Все узлы остаются равноценными до тех пор, пока их подписи проходят проверку.

В данном исследовании предложена модификация классического ориентированного графа за счет добавления динамического коэффициента доверия (trust) для каждого узла, который корректирует его вес при голосовании.

Постановка задачи

Описание предметной области. Технология распределенного реестра представляет собой новый подход к созданию баз данных, ключевой особенностью которого является отсутствие единого центра управления. Каждый узел составляет и записывает обновления реестра данных независимо от других узлов. Среди основных реализаций систем распределенного реестра выделяют блокчейн и ориентированные ациклические графы (Directed Acyclic Graph, DAG). Классический блокчейн (особенно при использовании протокола proof of work) требует значительных вычислительных мощностей и энергозатрат. В то же время DAG-структуры обеспечивают более высокую пропускную способность и экономию ресурсов за счет отказа от «тяжелых» операций майнинга. Концепция умного города предполагает интенсивное взаимодействие отдельных подсистем, в связи с чем ожидается быстрый рост цепочки транзакций. В таких условиях применение решений на основе ориентированных ациклических графов выглядит наиболее целесообразным.

Определение проблемы. Для решения перечисленных выше ограничений предлагается применить протокол распределенного консенсуса hashgraph, в котором события организованы в виде DAG-структуры, а узлы обмениваются «сплетнями о сплетнях» (gossip about gossip) [4]. На основе структуры графа проводится виртуальное голосование, что позволяет достигать высокой скорости подтверждения транзакций, масштабируемости сети и устойчивости к византийским отказам. Однако, протокол hashgraph надежно защищен от фальсификации истории до тех пор, пока доля вредоносных узлов составляет менее одной трети от общего количества узлов в сети. Кроме того, данный протокол не отслеживает, насколько часто каждый узел вел себя корректно или нет в прошлом. В результате, все узлы имеют равный вес голосов, и считаются полноценными участниками до тех пор, пока их цифровые подписи остаются валидными.

В данном исследовании для повышения защищенности систем распределенного реестра на основе DAG-графа и протокола hashgraph предлагается внедрить механизм доверия, который позволил бы изолировать вредоносные устройства, исключив их от участия в голосовании.

Модель доверия

Обоснование ввода модели доверия. Протокол hashgraph является устойчивым к византийским отказам [5], но в нем вводятся некоторые допущения:

- доля вредоносных (скомпрометированных) узлов не превышает одной трети от общего числа участников;
- для любых двух легитимных узлов любое сообщение от одного рано или поздно будет доставлено другому.

В реальных системах сложно представить, чтобы эти условия выполнялись всегда. Например, если вредоносный узел начнет отправлять множество событий, то существует вероятность того, что другие узлы, могут не получить легитимные события. Внедрение модели доверия позволит создать условия, при которых узлы

с пониженным доверием постепенно исключаются из процесса голосования, а их события перестают учитываться.

Описание реализации модели доверия. Формула (1) демонстрирует математический ввод фактора доверия p .

$$p:\omega_p = stake_p * trust_p, \quad (1)$$

где $trust_p \in [0, 1]$ является индикатором надежности, скорректированным в зависимости от истории валидации событий.

Формула (2) представляет сумму эффективных весов всех узлов.

$$T = \sum_p \omega_p. \quad (2)$$

Вычисление порогового значения минимального веса осуществляется согласно формуле (3).

$$s = \frac{2}{3} * T. \quad (3)$$

Таким образом, эффективный вес голоса узла вычисляется как произведение stake на текущий trust. Суммарный эффективный голосовой вес всех узлов используется для расчета порога в 2/3, необходимого для перехода событий в следующий раунд. Если коалиция свидетелей не набирает достаточного веса, событие остается в том же раунде, что гарантирует сохранение прогресса консенсуса. Добавление механизма доверия позволяет автоматически ограничивать влияние узлов, регулярно выпускающих некорректные события или подтверждая их, и усиливает вклад тех, кто долгое время вел себя честно.

Для оценки эффективности предлагаемого решения был разработан имитационный макет системы распределенного реестра умного города. На рис. 1 представлено исходное состояние графа. Все узлы имеют связь с остальными и участвуют в голосовании. Фиолетовым цветом отмечены вредоносные узлы, которые генерируют некорректные события или подтверждают их.

В процессе моделирования часть узлов визуально увеличивает-ся в размере, а другая часть уменьшается. Изменение их масштаба наглядно отражает текущий уровень доверия (чем выше значение




Рис. 1. Начальное состояние графа

доверительного фактора для конкретного узла, тем крупнее он отображается). Размер каждого узла вычисляется пропорционально значению его доверительного коэффициента, задаваемого на основе анализа исторических данных и текущих взаимодействий. Ребра служат наглядным представлением непосредственных связей каждого события с двумя его предками и, показывают, как сплетни об одном событии переходят к следующим. Когда узел создает новое событие, оно автоматически привязывается к своему предыдущему событию и к событию другого узла, с которым только что произошла синхронизация. Эти два отношения отображаются в виде отрезков: более толстая линия связывает событие с его собственным предком, а тонкая – с событием, полученным от другого узла. Ребра




Рис. 2. Результаты моделирования сегмента распределенного реестра

красного цвета обозначают неправильно сгенерированные события. Когда доверие одного из узлов падает до нуля, связи, ведущие от или к событиям этого узла, перестают отображаться, что говорит о его исключении из обмена сплетнями и голосования.

На рис. 2 представлен фрагмент моделирования, когда вредоносный узел № 1 полностью потерял доверие. Далее узел № 0 также теряет доверие и перестает участвовать в голосовании.

Таким образом, разработанная имитационная модель позволяет визуализировать структуру виртуального голосования, а также отразить динамику изменения репутации участников. Связи с узлами, доверие к которым снизилось до нуля, не отображаются, подчеркивая их фактическое исключение из процессов синхронизации.

Заключение

В ходе данного исследования для решения проблем построения безопасных систем распределенного реестра в умном городе предложено применить ориентированный ациклический граф, а также механизм «сплетен о сплетнях», обеспечивающие устойчивость к византийским отказам. Для повышения защищенности от атак, связанных с подделкой транзакций, дополнительно внедрена модель доверия, которая наделяет каждого участника динамическим весом голоса, зависящим от истории его корректного или некорректного поведения. Данный подход позволяет выявлять и изолировать вредоносных узлов на ранних этапах работы сети, снижая их влияние на процесс голосования и тем самым повышая общую надежность всей системы. Эффективность предложенного решения была продемонстрирована с помощью разработанной имитационной модели.

Исследование выполнено за счет гранта Российского научного фонда № 24-11-20005, <https://rscf.ru/project/24-11-20005/>; грант Санкт-Петербургского научного фонда (договор №24-11-20005 о предоставлении регионального гранта)

Библиография

1. **Калинин М. О.** Концепция защиты систем распределенного реестра умного города от специфических киберугроз / М. О. Калинин, А. Г. Бусыгин // Комплексная защита информации : Сборник материалов XXIX научно-практической конференции, Санкт-Петербург, 15–17 мая 2024 года. — Санкт-Петербург: Санкт-Петербургский политехнический университет Петра Великого, 2024. — С. 155–159.
2. **Калинин М. О.** Обеспечение безопасности технологии блокчейн в экосистемах Цифровой экономики / М. О. Калинин, А. С. Коноплев // Стратегическое управление цифровой трансформацией интеллектуальной экономики и промышленности в новой реальности : Монография. — Санкт-Петербург : ПОЛИТЕХ-ПРЕСС, 2024. — С. 396–421.
3. **Помазкова Е. Е.** Сравнительный анализ блокчейна и альтернативных технологий распределенного реестра // Международный журнал гуманитарных и естественных наук. 2019. № 4-2.

4. Berendea N., Mercier H., Onica E., Riviere E. Fair and Efficient Gossip in Hyperledger Fabric, in 2020 IEEE 40th International Conference on Distributed Computing Systems (ICDCS), Singapore, Singapore, 2020 pp. 190–200.

5. Schueffel P. Alternative Distributed Ledger Technologies Blockchain vs. Tangle vs. Hashgraph—A High-Level Overview and Comparison. 2017. — Режим доступа: <https://ssrn.com/abstract=3144241>.

APPLYING A TRUST MODEL FOR INCREASING THE DISTRIBUTED LEDGER SECURITY IN INFORMATION SYSTEMS OF SMART CITY

Oleg S. Vasiliev¹, Vasiliy M. Krundyshev²

Peter the Great St. Petersburg Polytechnic University,
St. Petersburg, Russia

¹vasiliev.os@edu.spbstu.ru, ²krundyshev_vm@spbstu.ru

Abstract. This paper examines the problem of ensuring the security of distributed ledger systems in digital infrastructures of a smart city. The following properties are characteristic of such smart city subsystems: blurring of the information perimeter, self-organization and mobility of network nodes, as well as low computing resources and disk space for most devices. In such conditions, to protect distributed registry systems from attacks related to transaction forgery, it is proposed to use a directed acyclic graph supplemented by a trust model.

Keywords. Distributed ledger system, directed acyclic graph, trust model, smart city.

* * *

УДК 004.056

doi:10.18720/SPBPU/2/id25-559

ФОРМИРОВАНИЕ ПОРТФЕЛЯ РЕШЕНИЙ В УПРАВЛЕНИИ ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТЬЮ

Ворошин Евгений Александрович¹, Полтавцева Мария Анатольевна²

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия

¹voroshin_ea@spbstu.ru, ²poltavtseva@ibks.spbstu.ru

Аннотация. Тема работы посвящена управлению информационной безопасностью критической информационной инфраструктуры. Целью работы является повышение эффективности управления информационной безопасностью субъектов критической информационной инфраструктуры, относящихся к малому и среднему бизнесу, путем разработки портфельного подхода к управлению информационной безопасностью. В ходе работы были сформулированы требования, проанализированы подходы к управлению и методы формирования портфеля решений. Предложен способ формирования портфеля, включающий модифицированную оценку возврата инвестиций в безопасность и постановку задачи поиска оптимального состава решений.

Ключевые слова. Критическая информационная инфраструктура, управление информационной безопасностью, оценка эффективности, управление портфелем, оценка портфеля, возврат инвестиций, дискретная оптимизация.

Введение

В современных условиях организации, являющиеся являющие субъектами малого и среднего бизнеса, подвергаются возрастающему вниманию киберпреступников и, как следствие, увеличению уровня угроз. Поэтому возникает необходимость в повышении уровня защищенности предприятий — субъектов критической информационной инфраструктуры, относящихся к малому и среднему бизнесу от кибератак путем рационального использования ограниченного ресурса организаций.

Постановка задачи

Проблема управления информационной безопасностью. В современной практике при управлении информационной безопасностью используются проектный и процессный подходы к управлению. Однако, ни один из подходов не обладает полным набором характеристик, отвечающих современным требованиям, таким как гибкость, адаптивность к внедрению новых решений и технологий, реализации постоянных процессов, а также применимость в условиях средней квалификации специалистов как управленческого, так и технического звена и возможность оптимизации, включая соблюдение граничных условий в техническом и финансовом плане.

Сегодня оба подхода необходимо комбинировать для решения поставленной задачи и использовать для этого некоторое третье решение. Таким решением становится построение системы управления проектами на основе процессного подхода. Преимущество такого объединения — в сочетании сильных сторон обоих методов: процессы обеспечивают стабильность, а проекты решают уникальные задачи предприятия. Формирование оптимального соотношения и выбор процессов и проектов для конкретного предприятия в области информационной безопасности основывается на портфельном подходе к управлению, изначально предназначенном для поиска устойчивых и/или оптимальных комбинаций из некоторого заданного пула решений в динамических условиях.

Портфельный подход к управлению и задача формирования портфеля. Портфель представляет собой совокупность различных решений по обеспечению информационной безопасности. Для управления информационной безопасностью предприятия необходимо выбрать способы его формирования, управления (в динамике), и критерии включения решений. Периодически, в силу изменений как требований, так и ландшафта угроз, портфель должен пересматриваться.

Портфель основывается на анализе информационных активов предприятия и модели угроз. Под информационным активом пред-

приятия в данном случае понимается совокупность программного и программно-аппаратного обеспечения и данные организации.

Управление портфелем осуществляется сотрудниками предприятия или передается на аутсорсинг и включает в себя анализ угроз (пересмотр модели угроз, если он не проводился чаще), выбор номенклатуры решений, оценку предложенных решений с точки зрения соотношения затрат к ущербу, внедрение и регулярный пересмотр решений входящих в портфель. Входными данными для работы с портфелем являются:

- Модель угроз предприятия.
- Перечень информационных активов предприятия.
- Нормативно — правовая база.
- Номенклатура решений в области информационной безопасности (как рыночная, так и доступная для реализации на предприятии собственными силами).

Выходными данными должен стать перечень решений, закрывающих обязательные требования, продиктованные нормативно — правовой базой и недопустимыми для предприятия рисками и максимальный перечень не обязательных требований в рамках доступного бюджета.

За последние годы теоретиками и практиками проектного управления было разработано множество моделей, методов и инструментов для принятия решений по отбору проектов в портфель [1,2]. В основе существующих подходов лежит широкий спектр различных дисциплин: от исследования операций и математического анализа до социологии. Каждый из них использует различные параметры, а также различные принципы их учета. Существует ряд работ, посвященных сравнению подходов к управлению портфелем. Однако данные исследования не содержат конкретных практических рекомендаций по их применению. Каждый из разработанных подходов к управлению портфелем проектов имеет свои преимущества и недостатки, рассматривает разные способы и критерии отбора проектов. Их обилие ставит вопрос выбора релевантной методологии с учетом особенностей конкретной задачи.

Систематизация методов формирования портфеля

Критерий сравнения	Экспертно-аналитические	Экономико-математические	Графические методы
Учет качественных характеристик проектов	+	—	—
Учет количественных характеристик проектов	+	+	+
Понятность	+	—	—
Возможность работать с большим количеством проектов	+	+	—
Учет стратегической направленности	+	—/+	—
Ориентации на достижение заданных целей	+	+	—
Объективность	—	+	—
Быстрота формирования портфеля	—	+	+
Нет необходимости использования специализированного ПО	+	+/-	+/-
Возможность относительно быстрой актуализации моделей	—	+	+
Простота принятия решений	+	+	—
Формализованные критерии оценки	—	+	—

Анализ методов формирования портфеля. В настоящее время имеется множество подходов, учитывающих не только количественные, но и качественные характеристики [3–7]. Их можно разделить на три основные группы: экономико-математические; экспертно-аналитические; графические (табл. 1). Оптимальным решением становится выбор наиболее простого (релевантного) из экономико-математических методов и использование графических подходов с элементами автоматизации расчетов для упрощения его применения в среде малого и среднего бизнеса. Особенностью работы с портфелем в поставленной задаче является необходимость использования простой оценки, близкой руководству организации, и учет временных характеристик.

Предложенный способ формирования портфеля. Так как рассматриваемый портфель сочетает в себе процессные и проектные решения, а не является в «чистом» виде портфелем проектов как это принято в обычной практике, в нем фигурируют различные модели стоимости решений во времени. Можно выделить следующие типовые модели:

- Разовая стоимость без дальнейшего поддержания («проектный» подход).
- Постоянная, относительно равномерная, стоимость поддержания («процессный» подход).
- Повышенная начальная стоимость, как правило связанная с внедрением того или иного решения и последующая относительно равномерная стоимость поддержания.
- Повышенная начальная стоимость, как правило связанная с внедрением того или иного решения, последующая относительно равномерная стоимость поддержания, но с включением отдельных повышенных затрат (на обновление, модернизацию и т. д.).

Для представления и описания приведенных типов мер предлагается использовать распределение затрат во времени, представленное в табличной или графической форме.

Оценка портфеля, в силу необходимости планирования, реализации, поддержания и вывода из эксплуатации различных ре-

шений (мер и средств) по информационной безопасности должна производиться на определенном интервале времени и периодически пересматриваться. В качестве базового горизонта планирования предлагается взять 1 год, как основной период планирования организации. Однако так же портфель может быть оценен как на

меньшем, так и на большем (например, пятилетнем) периоде. Тогда рассчитанная во времени на дискретный период T оценка $ROSI$ составит:

$$ROSI_T = \sum_{j=1}^{|T|} ROSI_j = \frac{ARO_T * SLE * MF - \sum_{i=1}^{|T|} TCO_i}{\sum_{i=1}^{|T|} TCO_i}, \quad (1)$$

где ARO — среднее количество инцидентов в указанный период времени в соответствии со статистическими данными, SLE — ожидаемые разовые потери, т. е. «стоимость» одного инцидента, а MF — также фактор снижения угрозы с помощью СЗИ. TCO_i — совокупная стоимость владения СЗИ или поддержания соответствующей меры в указанный период времени.

Общая стоимость портфеля $p_k \in P$, где P множество всех возможных портфелей которые могут быть сформированы, в этом случае будет складываться из совокупной стоимости всех входящих в него средств на протяжении всего временного периода планирования и составит:

$$p_k = \sum_{i=1}^{|S_k|} \sum_{j=1}^{|T|} TCO_{i,j} \quad (2)$$

где S_k — множество средств, входящих в конкретный портфель.

Формирование портфеля мер по информационной безопасности должно отвечать следующим требованиям:

- Иметь ограничение по предельному бюджету $pMAX$.
- Покрывать обязательные требования $Rq0 \subseteq Rq$ где Rq — общая совокупность всех мер защиты? даже от незначительных угроз.
- Покрывать максимум необязательных требований, продиктованных моделью угроз помимо нормативных требований и требований обеспечивающих снижение неприемлемых рисков $Rq1 \subseteq Rq$.

Тогда первое бюджетное ограничение можно сформулировать как граничное условие на стоимость портфеля $p_k \leq pMAX$.

Второе граничное условие можно сформулировать как граничное условие на содержание мер, закрывающих обязательные требования, среди мер, входящих в портфель k : $Rq0 \subseteq Rqk$.

И поставить задачу поиска оптимального набора портфеля как максимизацию множества фактически исполняемых требований. Такая задача будет иметь Парето-оптимальное множество решений, выбор между которыми должен быть сделан с учетом бизнес-логики конкретной организации и не оцениваемых напрямую в задаче характеристик.

Далее необходимо предложить вариант оценки целевой функции F . На основе вышеприведенного и используя матрицу соответствия требований и решений (мер и средств) по защите информации в базовом случае целевую функцию можно задать через общую приведенную стоимость портфеля:

$$F(Rq, S) = \frac{\sum_{i=1}^{|S_k|} ROSI_T}{|S_k|}. \quad (3)$$

Конечно, в этом случае в не равноценно учитывается полезность отдельных простых мер или, наоборот, комплексных решений, однако в условиях дефицита кадров и при учете прочих ограничений и требований к методике более сложные оценки могут оказаться излишне перегруженными.

Выбор способа решения задачи дискретной оптимизации при формировании портфеля не является определяющим. Учитывая счетное число как требований, так и возможных мер, и средств для их реализации, в данном случае возможно применение простейшего решения полным перебором вариантов. Также может использоваться любое средство или алгоритм решения аналогичной задачи.

Заключение

В работе был представлен способ оценки эффективности решений по информационной безопасности и портфеля таких решений на основе общепринятой оценки $ROSI$ с модификацией для учета временного интервала планирования. Предложенный способ сочетает в себе экономико-математический и графический подходы к оценке и отвечает требованиям к формированию портфеля работ по управлению информационной безопасностью в рамках портфельного подхода.

Библиография

1. **Кульгин Н. Б., Сурина А. В.** Модели и инструменты управления портфелем технологий предприятия // Системный анализ в проектировании и управлении. — 2024. — Т. 27. — № 2. — С. 322–329.
2. **Тюльпакова М. Ю., Горбачева Т. А.** Сравнительная характеристика методов оценки эффективности управления портфелем ценных бумаг // Региональная и отраслевая экономика. — 2025. — № 1. — С. 139–149.
3. **Нечаева И. М.** Модели формирования портфеля проектов в строительной отрасли // Вестник Санкт-Петербургского университета. Менеджмент. — 2021. — Т. 20. — № 2. — С. 242–262.
4. **Леонтьева Л. С., Макарова Е. Б.** Определение устойчивости портфеля проектов предприятий нефтегазового сектора экономики к внешним факторам // Интеллект. Инновации. Инвестиции. — 2021. — № 1. — С. 32–40.
5. **Славянов А. С.** Матричный метод формирования портфеля инвестиционных проектов в условиях неопределенности // Мягкие измерения и вычисления. — 2021. — Т. 40. — № 3. — С. 13–18.
6. **Хохлов Д. С., Слабинский С. В.** Формирование портфеля проектов на основе оценки проектной зрелости организации // Инновационная наука. — 2022. — № 8-1. — С. 33–35.
7. **Есенов М. К., Саркисов Д. А., Кеворкова Ж. А.** Методы выбора оптимального портфеля проектов при ограниченном инвестиционном капитале компании для обеспечения требуемой энергоэффективности // Проблемы экономики и юридической практики. — 2021. — Т. 17. — № 2. — С. 71–76.

INFORMATION SECURITY MANAGEMENT SOLUTIONS PORTFOLIO DEVELOPMENT

Evgenii A. Voroshin¹, Maria A. Poltavtseva²

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia

¹voroshin_ea@spbstu.ru, ²poltavtseva@ibks.spbstu.ru

Abstract. The topic of the paper is devoted to information security management of critical information infrastructure. The aim of the work is to increase the effectiveness of information security management of subjects of critical information infrastructure related to small and medium-sized businesses by developing a portfolio approach to information and information security management.

In the course of the work, the requirements were formulated, management approaches and methods of forming a portfolio of solutions were analyzed. A method of portfolio formation is proposed, including a modified assessment of the return on investment in security and the task of finding the optimal composition of solutions.

Keywords: critical information infrastructure, information security management, efficiency assessment, portfolio management, portfolio assessment, return on investment, discrete optimization.

* * *

УДК 330.1

doi:10.18720/SPBPU/2/id25-560

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ГИБРИДНОЙ ВЕРИФИКАЦИИ НАДЕЖНОСТИ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ ПРОМЫШЛЕННЫХ КИБЕРФИЗИЧЕСКИХ РАСПРЕДЕЛЕННЫХ СИСТЕМ

Шкодывев Вячеслав Петрович^{1,а}, Баскаков Дмитрий Евгеньевич^{2,б}

¹Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия;

²Общество с ограниченной ответственностью «Газинформсервис»,
Санкт-Петербург, Россия

^аshkodyrev@spbstu.ru, ^бBaskakov-D@gaz-is.ru

Аннотация. В работе исследуется применение методов машинного обучения для гибридной верификации надежности программного обеспечения промышленных киберфизических распределенных систем. Предложен комбинированный подход, сочетающий формальные методы, статический анализ и ML-модели для повышения точности обнаружения уязвимостей и снижения числа ложных срабатываний. Исследованы алгоритмы классификации аномалий и предсказания ошибок в распределенных средах. Результаты экспериментов демонстрируют эффективность гибридного подхода по сравнению с традиционными методами верификации.

Ключевые слова. Машинное обучение, гибридная верификация, киберфизические системы, промышленная кибербезопасность, формальные методы, статический анализ, обнаружение уязвимостей, надёжность ПО.

Введение

Современные промышленные киберфизические системы (КФРС) — сложные комплексы, объединяющие вычислительные, коммуникационные и физические компоненты. Исследования Kaspersky ICS CERT [1] показывают рост атак на промышленные предприятия, особенно в России и Центральной Азии (+0.9 % и +0.7 % заблокированных вредоносных объектов в 1 кв. 2025). Традиционные методы верификации ПО [2, 3] малоэффективны для КФРС из-за экспоненциальной сложности, трудностей формализации требований безопасности, временных ограничений реального времени и множества интеграций [4].

Машинное обучение (ML) активно используется в кибербезопасности (IDS/IPS, обнаружение вредоносного кода, прогнозирование угроз, автоматическое реагирование) и сокращает время реакции систем AIR [5,6]. Однако его внедрению мешают три барьера:

1. Нехватка качественных данных для обучения.
2. Уязвимость к adversarial-атакам [7].
3. Практические ограничения: высокая вычислительная сложность, неинтерпретируемость («чёрный ящик»), сложности интеграции с legacy-системами и высокая стоимость [8].

Более перспективным подходом для повышения надежности КФРС является применение ML для гибридной верификации ПО на стадии разработки [9]. Этот метод позволяет выявлять до 85 % уязвимостей на прединтеграционной стадии, сокращает стоимость исправлений (NIST [10]) и итерации тестирования на 30–40 %. ML обеспечивает непрерывную верификацию на соответствие стандартам (IEC 62443, ГОСТ Р 59593) в CI/CD, прогнозирует уязвимости, генерирует тесты (покрытие 90 %+) и оптимизирует ресурсы, сокращая сроки сертификации.

Формируется новая парадигма верификации КФРС — интеграция классических методов (модельная проверка [2], абстрактная интерпретация [11]), страдающих от роста сложности КФРС [12] и неполноты спецификаций) с ML-технологиями. Новые гибридные методы структурируются по направлениям: оптимизация

формальных методов ML, расширение статического анализа и динамическая верификация с ML.

Гибридная верификация преодолевает ограничения классических подходов, значительно повышая эффективность (сокращение времени, увеличение покрытия, снижение затрат), что подтверждается промышленными кейсами. Ключевые нерешенные проблемы — интерпретируемость решений ML и стандартизация метрик. Перспективы — создание специализированных ML-архитектур для КФРС и методик валидации.

Эффективная верификация ПО КФРС требует новых подходов, глубоко интегрирующих ML с сохранением формальных гарантий. Архитектура должна быть многоуровневой (модульные проверки, кластерный анализ, глобальная верификация) с применением специализированных ML-моделей (от предикторов аномалий до графовых нейронных сетей). Критически важно соблюдение временных ограничений реального времени через WCET-анализ и специализированные архитектуры (временные сверточные сети, например). Верификация надежности ПО КФРС с применением МО позволяет охватить критически важные метрики, а именно:

1. Надежность (англ. Reliability) КФРС есть вероятность безотказной работы системы:

$$R(t) = e^{-\lambda t}, \quad (1)$$

где λ — интенсивность отказов. ML-модели, такие как градиентный бустинг (XGBoost) позволяют прогнозировать отказы на основе исторических данных телеметрии, выявляя аномалии в работе компонентов с применением в качестве систем сбора метрик Elastic Stack [13].

2. Предиктивная оценка коэффициента готовности:

$$A = \frac{MTTR}{MTTF + MTTR}, \quad (2)$$

где MTTR (англ. Mean Time to Repair) — среднее время восстановления, MTTF (англ. Mean Time To Failure) — среднее время работы КФРС до первого отказа.

3. Отказоустойчивость (англ. Fault Tolerance) вычисляется через коэффициент восстановления после сбоя и времени до перехода в безопасное стабильное состояние (англ. Fail-Safe Time). В случае применения методов кластеризации (k-means, DBSCAN) можем создать методику выявления скрытых закономерностей между отказами.

Применение методов машинного обучения в задачах верификации ПО промышленных КФРС открывает не только технические, но и значительные экономические возможности. Традиционные подходы к верификации, такие как формальная проверка и ручное/автоматизированное тестирование, являются трудоемкими, дорогостоящими и часто неэффективными при масштабировании.

Традиционные методы формальной верификации требуют вычислительные ресурсы:

$$C_{\text{formal}} = k \times n^3, \quad (3)$$

где k — стоимость единицы верификации. При этом до 40% стоимости текущей разработки составляют как раз методы верификации [14]. Автоматизированный анализ логов методами типа Isolation Forest позволяет перейти к стоимости ресурсов

$$C_{\text{hybrid}} \sim O(n \log n) \quad (4)$$

Внедрение технологий машинного обучения позволяет снизить затраты, повысить эффективность процессов и минимизировать риски, связанные с ошибками программного обеспечения [15]. Одним из ключевых экономических эффектов применения МО является итоговое снижение затрат на тестирование и верификацию программного обеспечения. Экономия бюджета на верификацию может быть выражена следующей формулой:

$$\Delta C = C_{\text{formal}} - C_{\text{hybrid}}, \quad (5)$$

где ΔC — снижение затрат, C_{formal} — стоимость гибридной верификации, C_{hybrid} — стоимость гибридной верификации с использованием ML.

Аналитически можно выразить и экономию от предотвращения простоев КФРС:

$$\text{Savings} = (T_{\text{downtime}} \times C_{\text{hour}}) \times P_{\text{detection}} - C_{\text{hybrid}}, \quad (6)$$

где T_{downtime} — среднее время простоя, $P_{\text{detection}}$ — вероятность раннего обнаружения, C_{hybrid} — стоимость гибридной верификации.

Скорость вывода нового оборудования и программного обеспечения на рынок играет решающую роль в конкурентоспособности предприятия. Гибридная верификация, основанная на применении машинного обучения, значительно ускоряет этапы разработки, тестирования и сертификации за счет предварительного отсеивания потенциально проблемных участков кода и поведенческих сценариев.

Поддержка программного обеспечения после его внедрения — важный и дорогостоящий этап жизненного цикла продукта. Гибридная верификация позволяет заранее выявлять потенциальные дефекты в новых версиях ПО, что снижает количество потенциальных исправлений, вызовов техподдержки и необходимости срочных обновлений:

$$C_{\text{support}} = \alpha \times F_{\text{critical}} + \beta \times U_{\text{emergency}}, \quad (7)$$

где C_{support} — стоимость поддержки, F_{critical} — число критических ошибок, $U_{\text{emergency}}$ — количество срочных обновлений, α , β — какие-то весовые коэффициенты.

Применение машинного обучения для гибридной верификации надежности ПО промышленных КФРС показывает высокую эффективность в автоматизации процессов анализа, повышении точности выявления потенциальных ошибок и снижении затрат на тестирование и сопровождение ПО благодаря интеграции формальных методов и подходов на основе данных. Становится возможным построить модель, способную не только предсказывать уровень надежности компонентов системы, но и адаптироваться к изменяющимся условиям эксплуатации.

Заключение

В работе продемонстрирована эффективность применения методов машинного обучения в задачах гибридной верификации надежности ПО промышленных КФС. Использование комбинации формальных методов и ML-моделей позволит повысить точность выявления потенциальных ошибок, снизить затраты на тестирование и улучшить прогнозирование поведения системы в реальных условиях. В работе приведены соответствующие метрика качества и экономической эффективности предложенных методов.

Представленный подход открывает совершенно новые перспективы для автоматизации и повышения экономической эффективности процессов верификации в рамках цифровой трансформации промышленности.

Библиография

1. Kaspersky ICS CERT. Краткий обзор основных инцидентов в области промышленной кибербезопасности за четвертый квартал 2024 года. — М., 08 апреля 2025.
2. **Кларк, Эдмунд М., мл.** Верификация моделей программ: Model Checking / / Эдмунд М. Кларк, мл., Орна Грамберг, Дорон Пелед; Пер. с англ. В. Захаров [и др.]. — Москва: Изд-во Моск. центра непрерыв. мат. образования, 2002. — 416 с.: ил.: 22 см.; ISBN 5-94057-054-2 (в пер.).
3. **Lee E. A., Seshia S. A.** Introduction to Embedded Systems: A Cyber-Physical Systems Approach [Text] / Edward A. Lee, Sanjit A. Seshia. — 2nd ed. — Cambridge (Mass.): The MIT Press, 2017. — XXXI, 547 p.: ill. — (MIT Press series in electrical engineering and computer science). — ISBN 978-0-262-53381-2.
4. **Deval Bhamare, Maede Zolanvari, Aiman Erbad, Raj Jain, Khaled Khan, Nader Meskin.** Cybersecurity for industrial control systems: A survey 2020. Computers & Security, Vol. 89, p. 101677.
5. **Hemant Rathore, Swati Agarwal, Sanjay K. Sahay and Mohit Sewak.** 2018. Malware Detection Using Machine Learning and Deep Learning. In Big Data Analytics: 6th International Conference, BDA 2018, Warangal, India, December 18–21, 2018, Proceedings. Springer-Verlag, Berlin, Heidelberg, 402–411. https://doi.org/10.1007/978-3-030-04780-1_28

6. **Gauhar Ali, Sajid Shah, Mohammed ElAffendi.** Enhancing cybersecurity incident response: AI-driven optimization for strengthened advanced persistent threat detection, 2025, Results in Engineering, Vol. 25, p. 104078.

7. **Li Huayu, Namiot Dmitry.** A SURVEY OF ADVERSARIAL ATTACKS AND DEFENSES FOR IMAGE DATA ON DEEP LEARNING // International Journal of Open Information Technologies. 2022. №5. URL: <https://cyberleninka.ru/article/n/a-survey-of-adversarial-attacks-and-defenses-for-image-data-on-deep-learning> (дата обращения: 13.06.2025).

8. Gartner Top 10 Trends in Cybersecurity 2025. — 2025, URL: <https://www.gartner.com> (дата обращения: 13.06.2025).

9. **Yaming Tang, Fei Zhao, Yibiao Yang, Hongmin Lu, Yuming Zhou and Baowen Xu.** 2015. Predicting Vulnerable Components via Text Mining or Software Metrics? An Effort-Aware Perspective. In Proceedings of the 2015 IEEE International Conference on Software Quality, Reliability and Security (QRS '15). IEEE Computer Society, USA, 27–36. <https://doi.org/10.1109/QRS.2015.15>

10. NIST SP 800-218. Secure Software Development Framework. 2023.

11. Patrick Cousot and Radhia Cousot. 1977. Abstract interpretation: a unified lattice model for static analysis of programs by construction or approximation of fixpoints. In Proceedings of the 4th ACM SIGACT-SIGPLAN symposium on Principles of programming languages (POPL '77). Association for Computing Machinery, New York, NY, USA, 238–252. <https://doi.org/10.1145/512950.512973>

12. **Radoslav Ivanov, Taylor Carpenter, James Weimer, Rajeev Alur, George Pappas and Insup Lee.** 2021. Verisig 2.0: Verification of Neural Network Controllers Using Taylor Model Preconditioning. In Computer Aided Verification: 33rd International Conference, CAV 2021, Virtual Event, July 20–23, 2021, Proceedings, Part I. Springer-Verlag, Berlin, Heidelberg, 249–262. https://doi.org/10.1007/978-3-030-81685-8_11

13. **Osbert Bastani, Rahul Sharma, Alex Aiken, and Percy Liang.** 2017. Synthesizing program input grammars. In Proceedings of the 38th ACM SIGPLAN Conference on Programming Language Design and Implementation (PLDI 2017). Association for Computing Machinery, New York, NY, USA, 95–110. <https://doi.org/10.1145/3062341.3062349>

14. **Липаев, В. В.** Тестирование программного обеспечения / В. В. Липаев. — Москва: Синтез, 2010. — 320 с.

15. **Карпов, Ю. Г.** Model Checking. Верификация параллельных и распределенных программных систем / Ю. Г. Карпов. — Санкт-Петербург: БХВ-Петербург, 2010. — 560 с.

APPLICATION OF MACHINE LEARNING FOR HYBRID VERIFICATION RELIABILITY OF SOFTWARE INDUSTRIAL CYBER-PHYSICAL DISTRIBUTED SYSTEMS

Vyacheslav P. Shkodyrev^{1,a}, Dmitry E. Baskakov^{2,b}

¹Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia;

²JSC “Gazinformservice”, Saint Petersburg, Russia

^ashkodyrev@spbstu.ru, ^bbaskakov-D@gaz-is.ru

Abstract. The paper explores the application of machine learning methods for hybrid verification of software reliability in industrial cyber-physical distributed systems. A combined approach is proposed integrates formal methods, static analysis, and ML models to improve the accuracy of vulnerability detection and reduce the number of false positives. Algorithms for anomaly classification and error prediction in distributed environments are investigated. Experimental results demonstrate the effectiveness of the hybrid approach compared to traditional verification methods.

Keywords. Machine learning, hybrid verification, cyber-physical systems, industrial cybersecurity, formal methods, static analysis, vulnerability detection, software reliability.

* * *

ПРОМЫШЛЕННЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ (ПИИ’2025)

Сборник трудов
Всероссийской научно-практической конференции
3—4 июля 2025 года

Компьютерная верстка *Е. Г. Орловского*
Дизайн обложки *О. А. Костюшенко*

Подписано в печать 12.11.2025. Формат 60×84/16. Печать цифровая.
Усл. печ. л. 35,0. Тираж 20. Заказ 4151.

Отпечатано в Издательско-полиграфическом центре
Политехнического университета.
195251, Санкт-Петербург, Политехническая ул., д. 29.
Тел.: (812) 552-77-17; 550-40-14