

ISSN 2413 - 0133

Scientific journal

# ИНФОРМАЦИОННЫЕ И МАТЕМАТИЧЕСКИЕ ТЕХНОЛОГИИ В НАУКЕ И УПРАВЛЕНИИ

№2(42)/2026

# ИНФОРМАЦИОННЫЕ И МАТЕМАТИЧЕСКИЕ ТЕХНОЛОГИИ В НАУКЕ И УПРАВЛЕНИИ

Научный журнал  
№ 2 (42)



**EDITORIAL BOARD**

Ablameyko S.V.  
Arshinskiy L.V.  
Berestneva O.G.  
Boukhanovsky A.V.  
Bychkov I.V.  
Woern H.

Voevodin V.V.

Wolfengagen V.E.  
Gornov A.Y.  
Gribova V.V.  
Groumpos P.  
Zorina T.G.  
Kazakov A.L.  
Kalimoldaev M.N.  
Karpenko A.P.  
Komendantova N.P.  
Kureichik V.V.  
Lis R.  
Marchenko M.A.  
Massel L.V.  
Moskvichev V.V.  
Ovtcharova J.  
Popov G.T.  
Sidorov D.N.  
Smirnov S.V.  
Stennikov V.A.  
Stylios C.  
Taratukhin V.V.  
Khamisov O.V.  
Hodashinsky I.A.  
Chubarov L.B.

**РЕДАКЦИОННАЯ КОЛЛЕГИЯ ЖУРНАЛА**

Абламейко С.В., академик НАН Беларуси, Минск, БГУ  
Аршинский Л.В., д.т.н., Иркутск, ИрГУПС  
Берестнева О.Г., д.т.н., Томск, ТПУ  
Бухановский А.В., д.т.н., Санкт-Петербург, НИУ ИТМО  
Бычков И.В., академик РАН, Иркутск, ИДСТУ СО РАН  
Вёрн Х., Германия, Karlsruhe Institute of Technology (KIT)

Воеводин В.В., чл.-корр. РАН, Москва, НИВЦ МГУ

Вольфенгаген В.Э., д.т.н., Москва, МИФИ  
Горнов А.Ю., д.т.н., Иркутск, ИДСТУ СО РАН  
Грибова В.В., чл.-корр. РАН, д.т.н., Владивосток, ИАПУ ДВО РАН  
Грумπος Π., Греция, University of Patras  
Зорина Т.Г., д.т.н., Республика Беларусь, Институт энергетики НАН Беларуси  
Казаков А.Л., д.ф.-м.н., профессор РАН, Иркутск, ИДСТУ СО РАН  
Калимолдаев М.Н., академик НАН РК, Республика Казахстан, ИИВТ  
Карпенко А.П., д.ф.-м.н., Москва, МГТУ им. Баумана  
Комендантова Н.П., PhD, Австрия, Лаксенбург, ПАСА  
Курейчик В.В., д.т.н., профессор, Таганрог, ЮФУ  
Лис Р., Польша, Wroclaw University of Science and Technology  
Марченко М.А. д.ф.-м.н., профессор РАН, Новосибирск, ИВМиМГ СО РАН  
Массель Л.В., д.т.н., Иркутск, ИСЭМ СО РАН  
Москвичев В.В., д.т.н., Красноярск, ФИЦ ИВТ  
Овчарова Ж., Германия, Karlsruhe Institute of Technology (KIT)  
Попов Г.Т., Болгария, г. София, Технический университет  
Сидоров Д.Н., д.ф.-м.н., профессор РАН, Иркутск, ИСЭМ СО РАН  
Смирнов С.В., д.т.н., Самара, ИПУСС РАН  
Стенников В.А., академик РАН, Иркутск, ИСЭМ СО РАН  
Стилюс Х., Греция, Technological Educational Institute of Epirus  
Таратухин В.В., Германия, ERCIS, University of Muenster  
Хамисов О.В., д.ф.-м.н., Иркутск, ИСЭМ СО РАН  
Ходашинский И.А., д.т.н., Томск, ТУСУР  
Чубаров Л.Б., д.ф.-м.н., Новосибирск, ФИЦ ИВТ

**EXECUTIVE EDITORIAL**

Chief Editor Massel L.V.  
Editor Tuktarova P.A.  
Editor Kuzmin V.R.  
Editor Massel A.G.  
Tech. Editor Popova M.D.  
Designer Pesterev D.V.

Главный редактор  
Редактор  
Редактор  
Редактор  
Техн. редактор  
Дизайнер

Массель Л.В.  
Туктарова П.А.  
Кузьмин В.Р.  
Массель А.Г.  
Попова М.Д.  
Пестерев Д.В.

д.т.н., Иркутск, ИСЭМ СО РАН  
к.э.н., Иркутск, ИСЭМ СО РАН  
к.т.н., Иркутск, ИСЭМ СО РАН  
к.т.н., Иркутск, ИСЭМ СО РАН  
Иркутск, ИСЭМ СО РАН  
Иркутск, ИСЭМ СО РАН

**ИСПОЛНИТЕЛЬНАЯ РЕДАКЦИЯ ЖУРНАЛА**

**Учредитель:** Федеральное государственное бюджетное учреждение науки  
Институт систем энергетики им. Л.А. Мелентьева Сибирского отделения Российской академии наук  
(ИСЭМ СО РАН)

**Адрес учредителя, издателя и редакции**  
664033 г. Иркутск, ул. Лермонтова, 130  
Тел: (3952) 42-47-00 Факс: (3952) 42-67-96

Сайт журнала - <https://www.imt-journal.ru/>

Журнал включен в Российский индекс научного цитирования (РИНЦ). Номер контракта 202-04/2016.

Журнал включен в перечень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученых степеней кандидата и доктора наук (по состоянию на 29.03.2022) по научным специальностям 1.2.2; 2.3.1; 2.3.3; 2.3.5; 2.4.5.

Журнал зарегистрирован в Роскомнадзоре. Регистрационный номер ПИ № ФС 77 – 73539 от 31.08.2018.

Отпечатано в типографии «Дубль Принт»

Адрес типографии: 664046, г. Иркутск, ул. Волжская, 14

\*Подписка на журнал доступна со второго полугодия 2021 г.

Дата выхода 05.06.2026 г. Тираж 50 экз.

С С В У

© Издательство ИСЭМ СО РАН

Цена свободная (12+)

<b>Методологические аспекты информационных и математических технологий</b>	
<b>Черкашин А.К.</b> Иерархическая классификация экономических знаний	5
<b>Маркова Г.М., Барцев С.И.</b> Формирование универсального навыка рефлексии в условиях предельных моделей мира	18
<b>Методы, технологии и приложения искусственного интеллекта</b>	
<b>Привалов К.С.</b> Модифицированный подход к управлению параметрами генетического алгоритма на основе глубокого обучения с подкреплением	29
<b>Калушев К.А., Макаров И.А.</b> Анализ битемпоральных изображений системой управления коллаборативным роботом-манипулятором для определения вновь появившихся объектов в поле подсистемы технического зрения	42
<b>Горский М.С., Мосева М.С.</b> Разработка метода идентификации транспортного средства	55
<b>Математическое моделирование и его применение в научных исследованиях</b>	
<b>Колесникова С.И., Фоменкова А.А., Поляков В.В.</b> Оптимизация гибкой организации большого числа работ в задаче управления командной реализацией проектов	70
<b>Казаков А.Л., Лемперт А.А., Чан Туан Вьет</b> Построение быстрееших маршрутов без столкновений в анизотропной среде с динамическими препятствиями	87
<b>Рыбанов А.А., Каблов В.Ф.</b> Метрический анализ сходства композиционных данных для нечеткого поиска релевантных рецептов эластомерных смесей	102
<b>Математические, информационные и интеллектуальные технологии в энергетике</b>	
<b>Кулагина Л.В., Шефер Э.А.</b> Обучение сверточной нейросетевой модели методом Active learning для мониторинга безопасности объектов теплоэнергетики	117
<b>Короткова К.Е., Говорков А.С.</b> Методика построения цифровых двойников установок распределенной генерации с использованием нечетких моделей	128
<b>Довудов С.У., Дунаев М.П., Султонзода Ш.М., Хакимова М.А.</b> Исследование потерь мощности в полупроводниковых преобразователях фотоэлектрических установок	143
<b>Цифровая экономика и управление</b>	
<b>Туктарова П.А., Мансурова Ю.Т., Ялтонская Д.И.</b> Оптимизация программы мероприятий по кадровой безопасности предприятия методами дискретного программирования	153
<b>Ивашенко А.О.</b> Интеллектуальные модели профориентации: структурный анализ и формальная постановка	161
<b>Программные системы и комплексы</b>	
<b>Зароднюк Т.С.</b> Специализированные алгоритмы и программные средства оптимизации нелинейных управляемых динамических систем	177
<b>Дородных Н.О., Столбов А.Б., Юрин А.Ю.</b> Создание проблемно-ориентированных ассистентов для задач диагностики	190
<b>Камышев Н.Л., Исаева О.С.</b> Инструменты мониторинга данных устройств интернета вещей	206

	<b>Content</b>
<b>Methodological Aspects of Information and Mathematical Technologies</b>	
<b>Cherkashin A.K.</b> Hierarchical classification of economic knowledge	5
<b>Markova G.M., Bartsev S.I.</b> Formation of a universal reflection skill in the conditions of the limit world models	18
<b>Artificial Intelligence Methods, Technologies and Applications</b>	
<b>Privalov K.S.</b> A modified approach to controlling the parameters of a genetic algorithm based on deep reinforcement learning	29
<b>Kalushev K.A., Makarov I.A.</b> The analysis of bi-temporal images by a collaborative robot control system to determine new objects in the field of view of the technical vision subunit	42
<b>Gorskiy M.S., Moseva M.S.</b> Vehicle identification method development	55
<b>Mathematical Modeling and Its Application in Scientific Research</b>	
<b>Kolesnikova S.I., Fomenkova A.A., Polyakov V.V.</b> Optimization of assignment of a large number of works in the problem of managing team project implementation	70
<b>Kazakov A.L., Lempert A.A., Tran Tuan Viet</b> Time-optimal collision-free path planning in anisotropic environments with moving obstacles	87
<b>Rybanov A.A., Kablov V.F.</b> Metric similarity analysis of compositional data for fuzzy search of relevant elastomeric mixture formulations	102
<b>Mathematical, Information and Intelligent Technologies in Energy</b>	
<b>Kulagina L.V., Shefer E.A.</b> Training a convolutional neural network model using the Active Learning method for monitoring the safety of thermal power plants	117
<b>Korotkova K.E., Govorkov A.S.</b> Methodology for building digital twins of distributed generation systems using fuzzy models	128
<b>Dovudov S.U., Dunaev M.P., Sultonzada Sh.M., Hakimova M.A.</b> Analysis of power losses in semiconductor converters for photovoltaic installations	143
<b>Digital Economy and Management</b>	
<b>Tuktarova P.A., Mansurova Yu.T., Yaltonskaya D.I.</b> Optimization of the enterprise personnel security program using discrete programming methods	153
<b>Ivashchenko A.O.</b> Intelligent career guidance models: structural analysis and formal problem formulation	161
<b>Software Systems and Complexes</b>	
<b>Zarodnyuk T.S.</b> Specialized algorithms and software for optimizing nonlinear controlled dynamical systems	177
<b>Dorodnykh N.O., Stolbov A.B., Yurin A.Yu.</b> Creating domain-specific assistants for diagnostic tasks	190
<b>Kamyshev N.L., Isaeva O.S.</b> IoT device data monitoring tools	206

## Методологические аспекты информационных и математических технологий

УДК 005:51-7:330

DOI:10.25729/ESI.2026.42.2.001

### Иерархическая классификация экономических знаний

Черкашин Александр Константинович

Институт географии им. В.Б. Сочавы СО РАН,

Россия, Иркутск, *akcherk@irnok.net*

**Аннотация.** Естественная классификация научных знаний была и остается сложной задачей, решение которой позволило бы упорядочить имеющиеся и извлекать новые знания, полезные для исследований, практического использования и образования. Особенно это важно для экономической науки с возрастающим числом новых направлений изучения развития народного хозяйства с применением современных методов системного анализа и математического моделирования. Предлагается триадная схема классификации, основанная на принципе фрактального подобия и позволяющая в каждой таксономической позиции воспроизвести схему целиком. Классифицируются только типологические единицы – непересекающиеся слои знаний. Остальные группы знаний являются объединениями или комбинаторными сочетаниями независимых слоев. Для отображения этих правил из дифференциальной геометрии привлекаются процедуры расслоения на независимые слои информации разного содержания. Иерархическая классификация представлена несколькими уровнями на пути от простого к сложному и от абстрактного к конкретному знанию: данные, понятия, модели, интертеории, метатеории и метанаука-математика. Уровень метатеорий представлен тремя секторами членения на концептуальные, количественные и формальные знания, что соответственно включают политическую экономию, финансовый и математический (цифровой) анализ, учитывающий связи экономики с внешней и внутренней средой объектов хозяйствования. Интертеории сквозным образом в единых терминах описывают явления и в природе, и в обществе как системы определенного рода. На этой основе создаются модели различных экономических объектов, включая предприятия энергетической отрасли. Пространство представления данных и знаний имеет восемь независимых координат, включая координату экономического роста, поэтому в целом экономические знания имеют самостоятельное значение и выделяются среди знаний других наук.

**Ключевые слова:** классификация научных знаний, экономическая теория, фрактальная иерархия, метатеории и интертеории, базовые понятия, математическое моделирование, цифровая экономика

**Цитирование:** Черкашин А.К. Иерархическая классификация экономических знаний / А.К. Черкашин // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 05-17. – DOI:10.25729/ESI.2026.42.2.001.

**Введение.** Многообразие экономических наук (ЭН) – направлений изучения хозяйства на разных масштабных уровнях, отношений между людьми, населением и окружающей средой в процессе хозяйственной деятельности – требует наведения естественного порядка и организации научной информации в форме классификации накопленных сведений с указанием позиции разных экономических воззрений в общей системе научного знания. Профессор В.З. Баликоев, опираясь на свой опыт исследований проблем российской и мировой экономики и преподавания экономической теории, с полной ответственностью утверждает, что «в экономической литературе царит хаос в классификации экономических наук..., никто толком не понимает, ... каким содержанием наполняются термины: «конкретные», «специальные», «функциональные», «прикладные» и т.д. науки» [1, с. 112]. Делается попытка установить объективные связи, показывающие, какое фундаментальное значение имеет в классификации каждая ЭН [2].

Выбраться из «хаоса» неупорядоченного множества знаний можно двумя путями: опираясь на историю и логику экономических исследований, или применяя автоматические методы систематизации информации с созданием онтологий в виде графов-диаграмм [3]. Предлагается для иерархической, многоуровневой структуризации онтологического

пространства знаний использовать фрактальный подход [4]. Онтологии областей исследований являются важными инструментами для описания, изучения и анализа исследовательского ландшафта, автоматической классификации научных публикаций, направлений работ и прогнозирования тенденций развития науки [5].

Соответствующие проблемы типизации и классификации хозяйственных явлений и научных знаний ставятся и обсуждаются в учебниках, научных монографиях и отдельных статьях на данную тему. При этом отмечаются недостатки существующих классификаций и подчеркивается необходимость формирования научно обоснованной классификации разделов ЭН с опорой на современный экономический инструментарий [6]. Они нашли отражение в универсальной десятичной классификация (УДК), классификаторе ББК, в система JEL-классификации. Отсутствие единой классификации затрудняет определение сферы деятельности ЭН и требует объединения различных классификационных схем [7].

Базовые суждения о специфике объекта, предмета и метода экономики и классификации ЭН были заложены еще классиками экономического учения и выявлялись в процессе длительных обсуждений [8]. Д.Н. Кейнс предложил дихотомическую схему систематизации форм политико-экономического знания, включающую его деление на науку и искусство (прикладную экономику), а науку политической экономии – на позитивную науку о том, что есть, и нормативную – о том, что в идеале должно быть в отличие от действительного положения. В результате базовая структура знания получилась троичной: позитивная ЭН занята поиском закономерностей, нормативная – определением целевых идеалов, а искусство политической экономии – формулировкой правил достижения поставленных целей [9]. По схеме в позитивной науке основополагающая роль принадлежит чистой (абстрактной) теории, что противостоит конкретной политической экономии с индуктивным и дедуктивным методами исследования с учетом особых условий для отдельных случаев и закономерностей, имеющих силу в пределах данного периода времени или местоположения. Предложенная классификационная схема не потеряла своей актуальности и в настоящее время. Однако продолжающаяся сегментация (фрагментация) ЭН [10], появление новых областей науки [11] – цифровой, экспериментальной и вычислительной экономики, математической теории роста и развития, эконометрических исследований и др. – выявили новые проблемы, решение которых будет иметь общенаучное значение для совершенствования методов классификации.

Вместе с тем, развитие экономических теорий испытывает сейчас серьезные трудности, преодоление которых становится императивом времени [12]. К числу возможных теоретических направлений относится выделение метауровней знаний, например, методологии общего социального анализа [13] или социномики [14]. Такие исследования направлены на выявление аналогий между структурами, встречающимися в физике, химии, биологии и в общественных дисциплинах. Важным методологическим подходом к развитию экономической теории является принцип двойственности внутреннего наполнения и внешнего средового окружения социально-экономических систем [15]. Экономико-математическое моделирование считается неотъемлемым инструментом формирования теоретической и прикладной экономики [16].

Целью данного исследования является построение иерархической классификации научных знаний и определение места различных ЭН в этой классификационной системе для обоснования моделей и методов решения задач изучения хозяйственной деятельности.

**1. Основные понятия и гипотезы.** Главный недостаток существующих классификаций экономических знаний – отсутствие научно обоснованной системности в изложении экономических дисциплин, опирающейся на строгую иерархию восхождения от общего к частному [6]. Философ-позитивист О. Конт (1798–1857) впервые предложил «естественное» упорядочение научных дисциплин по их иерархии, от математики до социологии, чтобы

отразить растущую сложность объектов исследований и степень познавательного развития наук [17]. Сложность исследования, как правило, возрастает с повышением уровня организации материи, где по иерархии развитые естественные науки (физика, химия) находятся на вершине, а социальные науки – у подножия пирамиды знаний. Науки на вершине иерархии демонстрируют более быстрые темпы развития и более высокий консенсус ученых, чем те, что находятся внизу [18].

По степени охвата объекта исследования, ЭН в системе общественных наук делятся на общие и конкретные [19]. В состав общих входят политическая экономия, история народного хозяйства, история экономической мысли, теория управления общественным производством и другие. Конкретные ЭН изучают отдельные аспекты экономического строя общества и разграничиваются по межотраслевому (функциональному), отраслевому и региональному (страноведческому), информационному (аналитическому), историко-экономическому и междисциплинарному признакам. К межотраслевым наукам относятся финансы, кредитно-денежное обращение, ценообразование, экономика труда, экономика капитальных вложений, маркетинг, менеджмент и т. п., специализирующиеся на детальном количественном анализе важнейших процессов во всех отраслях и на разных уровнях хозяйственной деятельности.

Отраслевые ЭН посвящены углубленному изучению особенностей работы отдельных отраслей экономики: промышленности, энергетики, сельского хозяйства, транспорта, строительства, непроектируемой сферы и т.д. Региональный аспект охватывает экономику различных стран и регионов. К частным информационно-аналитическим наукам относятся статистика, анализ хозяйственной деятельности, бухгалтерский учет и т.д. Они занимаются совершенствованием методов сбора и обработки экономической информации. Историко-экономическое знание представлено экономической историей, историй экономических учений и др. Наконец, междисциплинарные науки – это экономическая география, экономическая психология, конституционная экономика и др.

По практическому значению выделяют фундаментальные и прикладные ЭН. Фундаментальные науки изучают объективные экономические законы и обосновывают пути их практического использования. К ним относятся экономическая теория, философия и методология ЭН, институциональная теория, эволюционная теория, компаративистика и др. Прикладные науки решают частные и локальные задачи и разрабатывают конкретные экономические программы, а также мероприятия по совершенствованию экономических процессов. По масштабу исследования ЭН делятся на микроэкономику, изучающую деятельность компаний, домохозяйств, и макроэкономику, что исследует национальное хозяйство в целом. Особое место занимают статистика, бухучет, анализ хозяйственной деятельности, экономико-математические методы; они выявляют количественные взаимосвязи и статистические закономерности общественного воспроизводства.

Основу ЭН составляют фундаментальные разработки в области теории. Современная вузовская программа по экономической теории – это набор различных дисциплин, прежде всего политической экономии и экономикс [19]. Политическая экономия изучает экономические, общественно-производственные *отношения* между людьми, складывающиеся в процессе производства, распределения, обмена и потребления жизненных благ, а также общие законы, регулирующие хозяйственную жизнь общества, становления, развития, обогащения и отмирания социально-экономических систем. Экономикс занимается вопросами использования редких экономических ресурсов с целью удовлетворения материальных потребностей общества в микро- и макроэкономических масштабах.

Возникают проблемы разграничения экономики со смежными науками, например, экономической географией, которая, в свою очередь, напрямую контактирует с физической географией. Продолжается работа по поиску научных принципов построения классификаций,

и имеющийся опыт в этой области [20] дает возможность применить выявленные закономерности для ЭН-систематизации. Выделяются иерархические в виде пирамиды и неиерархические (гетерархические) классификации с фрактальными свойствами самоподобия.

**2. Расслоение на многообразиях.** В 1969 г. доктор Д. Кэмпбелл опубликовал статью [21], где предложил схему наложения узких специализаций исследований, похожую на чешуйчатый покров рыбы. Этой схемой Д. Кэмпбелл пытался метафорически представить науку в целом, обеспечить всезнание на пути к "всеобъемлющей, интегрированной мультинауке". Предполагалось, что дисциплинарные кластеры не вступают в непосредственный контакт, т.е., перекрываясь, они как бы находятся в независимых плоскостях [21]. К сожалению, публикация Д. Кэмпбелла оставила без ответа вопросы о механизмах обеспечения коммуникации между дисциплинами [10]. Сегодня для этого требуется создание серьезной теории о распределенной природе (типологии и классификации) знаний.

Процесс сегментации формализуется в виде процедур расслоения из теории множеств и дифференциальной геометрии. Расслоение в математике – непрерывное отображение  $\pi: X \rightarrow B$ , когда каждый элемент  $b \in B$  является образом одного или нескольких элементов множества (пространства)  $X$ . Обратное отображение  $\pi^{-1}: b \rightarrow X$  развертывает  $b \in B$  в  $X$  в виде множества непересекающихся слоев  $Y = \{X_b\}$ , где  $X_b \subset X$  и  $X_b \subset Y$ ,  $Y$  – расслоенное пространство, «рыбная чешуя» над множеством  $B$  в пространстве  $X$ . Разные слои функционально эквивалентны через отображение сравнения  $\varphi: X_b \rightarrow X_v$  определенного типа. В методологии познания через расслоение, объект исследования – это полисистема, множество систем разного рода.

Перераспределение знаний  $\xi \in X$  по теориям осуществляется на основе представлений о ядре каждой теории  $b \in B$ , соответствующим набору основных понятий и аксиом. Каждая самостоятельная теория (научно-информационный слой) описывает объект только как систему особого рода, признаки которой встречаются в объектах любой природы, т.е. каждая теория является сквозной интертеорией (ИТ) – «большой теории», отображающей свойства природы, хозяйства и населения в единых системных терминах. Всякое знание – это полисистема знаний, каждая система которой описывается моделью специальной ИТ. Число ИТ велико, и они послойно и не пересекаясь потенциально полностью покрывают пространство научных знаний. Внутренняя фрагментация всякой ИТ на специальные теории идет по степени сложности развития и саморазвития объектов исследования, так что законы состояния и изменения физической природы и человеческого общества предметно различаются, хотя могут относиться к системам одного рода, одной ИТ, что наглядно проявляется в однотипности используемых математических формул [22].

Новые возможности для количественного анализа открываются при использовании процедур расслоения над поверхностями многообразий, задаваемых системными функциями  $F(x)$  нескольких независимых переменных  $x = \{x_i\}$ ,  $i = 1, 2, \dots, n$ . Многообразие связей изучается по частям (информационным слоям) с помощью уравнений касательных преобразований Лежандра  $F(x) \rightarrow F^*(a)$ , переводящих функцию  $F(x)$  исходного набора переменных  $x = \{x_i\}$  в функцию  $F^*(a)$  двойственных переменных  $a = \{a_i\}$ :

$$a) F(x) = \sum_i a_i x_i + F^*(a); \quad b) F^*(a) = -\sum_i a_i x_{0i} + F(x_0); \quad a_i = \frac{\partial F}{\partial x_i}, \quad (1)$$


$$f(y) = a_1 y_1 + \dots + a_i y_i + \dots + a_n y_n = \sum_{i=1}^n \frac{\partial f(y)}{\partial y_i} y_i, \quad a_i = \frac{\partial f(y)}{\partial y_i} = \frac{\partial F(t, x(t))}{\partial x_i}, \quad (2)$$

$$F(x) = f(y) + F(x_0). \quad (3)$$

Здесь функция  $F(x)$  – локальное представление касательной гиперплоскости (слоя) к поверхности  $F(x)$ , характеризующей ситуацию  $F(x_0)$  в окрестности точки  $x_0=\{x_{0i}\}$ . Функция Лежандра  $F^*(a)$  выражает скрытое знание, недоступное прямому наблюдению, но проявляющееся через обратное преобразование  $F^*(a)\rightarrow F(x)$ . Функция  $f(y)$  (2) отражает связи двух наборов переменных  $a=\{a_i\}$  и  $y=\{y_i\}$ ,  $y_i=x_i-x_{0i}$ . Она одинаково и позитивно описывает системы различного содержания, масштаба и ориентации действия в «чистом виде», без учета параметров точки приложения  $x_0=\{x_{0i}\}$ . Величины  $x_0$  и  $F(x_0)$  обычно трактуются как характеристики среды (входные условия). Поверхность  $F(x_0)$  является огибающей множества послонных функций  $f(y)$  с разными  $x_0$  и так обеспечивает единство слоев.

Уравнения (1) и (2) имеют множество экономических приложений, позволяют учесть с помощью относительных переменных (симптомов, отклонений)  $y = x - x_0$  влияние отдельно факторов  $x$  и условий  $x_0$ . Простой пример: пусть  $F(x)$  – доход (выручка),  $F^*(a)$  – прибыль,  $F(x) - F^*(a)$  – себестоимость, складывающаяся из количества  $x_i$  и цены  $a_i$  ресурсов;  $x_{0i}$ ,  $F(x_0)$  – общественно необходимые затраты ресурсов и рентные доходы  $F(x_0)$  в данной социально-экономической среде. Другой пример:  $F(x)$  – инвестиции в промышленность и сельское хозяйство региона,  $x_i$  – объемы текущего производства и  $a_i$  – акселераторы роста по отраслям;  $F^*(a)$  – реакция на внешние инвестиции в существующей хозяйственной среде  $F(x_0)$ . Решения уравнения (2) порождают различные оценочные метрики  $f(y)$ , в частности, производственные функции типа функции Кобба-Дугласа  $f(y)=AK^\alpha L^\beta$  связи объёма выпуска  $f(y)$  с затратами капитала  $y_1 = K$  и труда  $y_2=L$  при общей факторной производительности  $A$  и с нормировкой коэффициентов эластичности  $\alpha + \beta = 1$ ; в данном случае  $a_1$ ,  $a_2$  – предельная капитало- и трудоэффективность с постоянной отдачей от масштаба производства.

Уравнение (3) описывает разложение функции  $F(x)$  исследуемого явления (феномена) на объясняющую функцию слоя  $f(y)$  и контекстное значение  $F(x_0)$ . В структуре (рис.1) слоя величина  $F(x_0)$  занимает позицию центра и соответствует норме существования явления  $F(x)$ , когда  $x = x_0$ ,  $y=0$ ,  $f(y)=0$ ,  $F(x)=F(x_0)$ . Выделяется граница допустимых отклонений  $|f(y)| \leq f_0$  – норматив, «красная линия», за которой находится периферия с заметными отклонениями от поверхности многообразия  $F(x)$ :  $f(y)=F(x)-F(x_0)>f_0$ . Эта схема соответствует распространенной экономико-географической модели «центр-периферия» и другим моделям центрального типа, которые могут быть многомерными по числу  $n$  локальных координат  $y=\{y_i\}$ .



**Рис. 1.** Внутренняя структура касательной плоскости  $f(y)$  в точке  $x_0$  фоновой поверхности многообразия  $F(x)$  с системой локальных координат  $y=\{y_1, y_2\}$  состоит из: 0 – центра  $F(x_0)$ , 1 – ядра с границей  $f_0$ , 2 – периферии (пояснения в тексте)

Набор перечисленных утверждений, определяющих структуру слоя, составляет его типовую аксиоматическую основу:


$$a) F(x) = F(x_0); \text{ б) } f(y) = f_0; \text{ в) } f(y) = \sum_{i=1}^n a_i y_i \quad (4)$$

– всегда существуют норма, норматив и универсальный закон изменения системы определенного рода. По этой причине все аксиоматические теории эквивалентны, получаются одна из другой заменой в аксиомах понятий одной теории на понятия другой.

В политической экономии нормативные законы сохранения постулируют защиту права собственности – права владения  $F(x_0)$ , пользования и распоряжения  $f_0$  своим имуществом, как одного из основных составляющих стабильного и развивающегося общества. Есть жесткие требования исполнения бюджета  $f(y)$ , количественно выражающего баланс текущих доходов и расходов в пределах утвержденных смет, который не должен меняться  $f(y)=f_0=const$ .

Последовательная операция расслоения уже над отдельным слоем обеспечивает каждому слою иерархическую фрактальную структуру, похожую на волновой процесс, когда в классификации каждая таксономическая позиция разбивается на несколько субпозиций таксонов нижнего уровня, любой из которых раскрывается через более дробные типологические категории (рис.2). Выделяются радиальные от центра и орбитальные по кругу классификационные связи (см. рис.2), которые отражают отношения тождества противоположностей (симметрии). Все орбитальные узлы представляют собой непересекающиеся слои-типы существования информации, связанные отображениями. Классификация научных знаний имеет сложную разветвленную структуру с фрактальными свойствами и иерархическим ранжированием.

Формально таксономическая единица характеризуется положением в декартовой системе координат – прямого произведения  $X_1 \times X_2 \times X_3$  отдельных координатных слоев  $X_b$  разного уровня с линейным порядком их значений  $y=\{y_i\}$ , что выглядит как многомерный куб наподобие комбинаторной ЭН-классификации Е.В Попова [6]. Естественность классификации определяется правильностью выделения содержания координатных слоев на каждом иерархическом уровне и их межуровневым подобием. В иерархической структуре необходимо, чтобы концу каждой стрелки соответствовала одна таксономическая позиция (см. рис.2). Классификационная позиция объекта кодируется последовательностью символов на пути от центрального (верхнего) узла к выделенной позиции. Прямые и обратные переходы обеспечиваются оборачиванием стрелок: дедуктивный вывод – движением от общего к частному, и индуктивный процесс – от частного к общему.



**Рис. 2.** Фрактально-волновая модель архетипа иерархической классификации: 1 – центр; 2 – производные позиции; 3 – локальные координаты разного уровня; 4 – распространение волн от вторичных источников; 5 – фронты волны; O, A, B, C, X, x – уровни классификации

**3. Классификация экономических знаний.** В данном случае классифицируются ЭН-знания разного уровня обобщения, а не собственно экономические науки. Онтологическая схема (см. рис. 1-2) заполняется знаниями с использованием систематического обзора публикаций, ориентируясь на библиографические указатели и поисковые системы интернета по заданной тематике.

Выделяются следующие уровни интеграции научной информации (см. рис.2): исходные данные (орбитальный уровень **X**), обобщенные понятия (уровень **X**), структурные модели (**C**) и системные теории разных предметных областей (**B**), метатеории (**A**) и метанаука-математика (центр **O**). Центральное и высокое положение математики подразумевает, что любое знание можно описать, объяснить и понять с использованием математических структур, например, методами математического моделирования или эконометрики.

**3.1. Метатеории.** С экономической точки зрения интересен метатеоретический уровень нормативных ЭН-исследований **A**, где расположены знания герменевтического содержания. Основу современной герменевтики как науки составляют проблемы интерпретации и понимания «текстов», воспринимаемых в широком смысле, как всякая объективная информация по всей иерархии от **A** до **X**. Исследования в этой области, по сути, расшифровывают формулу (3), где функция  $F(x)$  рассматривается, как наблюдаемая закономерность, а  $f(y)$  – как скрытый в ней закон (модель), проявляющийся в конкретных условиях  $F(x_0)$ : закон  $f(y)$  трактуется с позиции  $F(x_0)$ , когда частный случай  $F(x)$  подводится под общее нормативное понятие  $F(x_0)$ . Здесь  $f(y)$  – функция объяснения значимого смысла, а  $F(x_0)$  – функция понимания смыслового значения явления  $F(x)$ . Смысл производственной деятельности состоит в создании  $f(y)$  товаров и услуг для удовлетворения потребностей людей с использованием набора экономических факторов  $x=\{x_i\}$ . Эффективность производства выражается величиной прибыли  $F^*(a)$ , включая разные виды ренты  $F(x_0)$  (см. формулы (1)), обеспеченные средовыми предпосылками отчуждения и накопления капитала, формирования прибавочной стоимости и прибавочного продукта для экономического роста.

Экономическая география в составе географических исследований основным предметом изучения считает географическую среду, включающую как природную, так и социально-экономическую составляющие, что детерминируют хозяйственные процессы [23]. Экономическая деятельность в процессе освоения земель, инфраструктурного обустройства территории совершенствует окружающую среду, увеличивает национальное богатство. Герменевтический подход становится уместным, когда элементами научного внимания являются метасистемы  $F(x)$ , объединяющие объект-систему  $f(y)$  и его окружающую среду  $F(x_0)$ . Сходные задачи ставит метаэкономика, предоставляющая более глубокое и комплексное понимание экономической реальности  $F(x)$ , учитывая широкий спектр влияющих факторов  $x$  и условий  $x_0$ .

Область **A** герменевтических знаний подразделяется на три самостоятельных направления – эмпирического **A<sub>1</sub>**, концептуального **A<sub>2</sub>** и математического **A<sub>3</sub>** анализа (см. рис. 2). В секторе **A<sub>2</sub>** решаются задачи общего содержания с применением набора методов качественных исследований и историко-философских изысканий. По характеру знаний в область **A<sub>2</sub>** попадает политическая экономия, принимаемая в качестве основного метатеоретического и методологического фундамента всех ЭН на герменевтическом уровне трактования контекста внешнего и внутреннего влияния (спонтанного и осознанного управления). В качестве иллюстраций теоретического материала широко используются чертежи, схемы и графики, благодаря их способности наглядно представлять явления в форме, доступной для понимания [24].

Эмпирический сектор **A<sub>1</sub>** связан с получением и обработкой данных, что одинаково важно и в естественных, и в гуманитарных науках, для проверки гипотез и практических

расчетов, в чем выражается «искусство» экономики с признаками и описательного и точного знания. С одной стороны,  $A_2$ , экономика – это система экономических отношений, с другой,  $A_1$ , – связи многочисленных показателей. Переход в количественную область анализа  $A_1$  предполагает измерение экономических качеств, что осуществляется посредством финансовых оценок уже не в различных материальных, а в единых стоимостных значениях. Это облегчает построение вычислительных моделей балансового типа не в натуральном, а в денежном выражении. Проявляется двойственность экономики и финансов, стоимости и цены, собственности и богатства. Со временем формат денег значительно изменился при сохранении их базовых функций. Из материальных ценностей они превратились в платежные знаки, а теперь в цифровые валюты, не имеющие физического выражения, но удобные для совершения транзакций и компьютерного счета. Такие валюты существуют лишь виртуально в электронном, математическом виде, но связанные с ними экономические отношения обязательно документально подтверждаются на материальных носителях.

Экономика  $A_2$ , финансы  $A_1$  и цифровизация  $A_3$  – это независимые, взаимозаменяемые  $A_1 \leftrightarrow A_2 \leftrightarrow A_3$ , дополняющие друг друга ЭН-дисциплины орбиты герменевтического знания. Фиксируется материальная, денежная и цифровая эквивалентность процессов и результатов производства, а знания разных секторов отличаются лишь формой интерпретации понятий, толкованиями смыслов изучаемых явлений.

Для численных расчетов необходимо знать законы  $f(y)$ , что формулируются в системных ИТ на следующем уровне **В**.

**3.2. Интертеории.** Объективная реальность отображается в науке в виде полисистемы интертеорий, каждая из которых однотипно, сквозным образом описывает природные и социальные объекты, как системы особого рода в соответствующей теоретической интерпретации в своих базовых понятиях и аксиомах. В позитивной ЭН это выражается в формировании системной парадигмы [25-27], призванной интегрировать положения традиционной экономической неоклассической, институциональной и эволюционной теорий на базе общей теории систем и пространственно-временного анализа [28]. Системы бывают общего содержания, а также динамические, функциональные и т.д. Для каждой из них необходимы сквозные ИТ-описания и моделирование, использующие в качестве образца аксиоматику (4), где все переменные и функции понимаются по-своему [25, 29]: объект исследования – полисистема, предмет исследования – множество систем данного рода.

Экономическая система – одна из разновидностей систем определенного рода, т.е. должна пониматься своеобразно в зависимости от постановки задачи и выбора модели и математических средств исследования. В обобщенном смысле экономическая система – это множество отношений объектов и субъектов хозяйственной деятельности. Предметом изучения здесь становятся системы разнообразной деятельности, включая экономическую, подробно рассматриваемую в рамках политической экономии.

Особенности представления ИТ-знаний лучше прослеживаются в секторе  $A_1$  количественного анализа связи  $F(x)$  переменных  $x = \{x_i\}$  в различных системных интерпретациях пространства базовых понятий и аксиом (4). Каждая ИТ по-своему объясняет экономические явления, например, с точки зрения влияния факторов производства.

**3.3. Модели.** ИТ-знания уровня **С** (см. рис. 2) относятся к искусству ЭН и используются для создания концептуальных, эмпирических и математических моделей экономических объектов разного типа, выделенных по регионам, отраслям и направлениям хозяйственной деятельности, что связаны с различием внутренней среды моделируемых объектов. На основе разных ИТ создаются модели, как частные теории конкретных явлений для объяснения и понимания наблюдаемых закономерностей. Классификация моделей по сути является

классификацией типов объектов, прежде всего по хозяйственным отраслям и секторам экономики.

Отраслевые модели знаний представлены экономикой промышленности, сельского хозяйства, энергетики, строительства и торговли, а также их подотраслей. Так, топливно-энергетический комплекс включает в себя основное производство (предприятия топливных и электроэнергетических отраслей) и вспомогательное производство (предприятия специализированного машиностроения). В экономике сельского хозяйства выделяется экономика растениеводства и животноводства; у каждой из которых есть своя специфика проявления экономических законов, выраженная в характерном сдвиге параметров моделей.

Сейчас модели энергетических объектов создаются, как цифровые двойники – виртуальные копии, где можно тестировать различные сценарии эксплуатации систем. В зависимости от характера решаемых задач выбирается одна или несколько системных ИТ, понятия которых применяются для описания явлений и построения их моделей. Своеобразие экономических систем отображаются в знаниях с помощью параметров – понимаемых по-разному исходных данных. Например, логистика хорошо отражается в формулах ИТ динамических систем, учитывающих особенности закупки, перевозки, продажи и хранения грузов.

**3.4. Понятия.** На  $X$  уровне (см. рис.2) накопленные знания размещаются в пространстве независимых координат (слоев информации). В фасетной классификации Ш.Р.Ранганатана [30] все предметы обозначены в многоаспектном фасетном пространстве координат-изолятов. Нами по схеме удвоения предложен [25] список фасетов-указателей от простых по форме свойств к более сложным качествам: временное  $X_1$  (возраст), пространственное  $X_2$  (масштаб), инертное  $X_3$  (масса), мобильное  $X_4$  (потoki, энергия), вегетативное  $X_4$  (рост), соматическое  $X_5$  (активное движение), экономическое  $X_7$  и социальное  $X_8$  развитие. В пространстве этих координат позиционируются различные объекты и соответствующие им знания в чистом виде и в комбинации (идентификаторе) специального знания. Законы интертеорий действуют и по одному, и по всем из этих координатных слоев.

В частности, как самостоятельный выделяется указатель «экономика»  $X_7$ , не пересекающийся с вектором  $X_8$  социальных знаний. Однако допускается комбинация  $X_7 \times X_8$  знаний о социально-экономических системах. Сочетание  $X_2 \times X_7$  соответствует пространственной экономике – геоэкономике, которая на уровне  $B$  в рамках ИТ динамических систем  $X_4$  описывает модели  $C$  транспортных перевозок, а на уровне  $A$  представлена экономической географией транспорта. Код  $(X_4 + X_5)$  соответствует биологии, а код  $(X_4 + X_5) \times X_7$  – сельскому хозяйству. На оси  $X_2$  отображаются обособленные объекты разного масштаба: экономика подразделяется на макро- и микроэкономику.

**3.5. Данные.** На  $x$ -уровне исследований по каждому объекту собираются сведения  $x = \{x_i\}$ , которые соотносятся с атрибутами  $X_i$  информации  $x_i \in X_i$ , чтобы определить положение объекта в координатном пространстве признаков  $x \in X = \{X_i\}$ . В границах некоторого временного интервала наблюдений рассчитывается средняя норма  $x_0$  состояния объекта по каждому признаку  $x_0 = \{x_{0i}\}$ , идентифицирующая объект. Статистические значения  $x_0 = \{x_{0i}\}$  – это изначально неизвестные величины, для исчисления которых необходимы массивы данных. С их помощью вычисляется относительная величина признаков  $y = x - x_0$ . Выделенные диагностические показатели интерпретируются в терминах интертеории, соответствующей задаче исследования. Создается типовая ИТ-модель  $f(y)$  и модель объекта  $F(x)$  с учетом отраслевого смещения  $x = y + x_0$ . Наконец, идентифицируются условия внешней среды, и по ИТ-модели проводятся расчеты системной функции слоя  $F(x) = f(y) + F(x_0)$ .

Этот алгоритм отражает последовательность движения по уровням организации знаний от частного к общему, выражая естественный ход мышления, подкрепленного моделями и методами решения экономических проблем:

$$x \rightarrow x_0 \rightarrow y = x - x_0 \rightarrow f(y) \rightarrow F(x) = f(y) + F(x_0).$$

**4. Выводы.** Классификация экономических знаний строится на основе фрактальной иерархии методов и результатов исследования экономики и других наук. Такая классификация является частью общей классификации научного знания и проявляется по научным направлениям в соответствии с координатами понятийного пространства, в котором экономика соответствует самостоятельному вектору изучения объектов природы и общества – независимому слою познания, который в идеале можно рассматривать, как изолированную от других областей знания, в том числе отдельно от социальных наук. Их совместная разработка возможна только в комплексе дополнительных знаний или в рамках специальных интертеорий, описывающих в единых системных терминах природу, хозяйство и население.

Первое разделение ЭН происходит на уровне герменевтических метатеорий на три сектора: общего концептуального, количественного и формального знания, что соответственно включают политическую экономию, финансовый и математический (цифровой) анализ. В политэкономии исследуются экономические отношения, что создают сложные системные образования, учитывая взаимозависимость общества и природы, связи с географической средой. Знания в секторах классификации дополняют друг друга, поэтому экономическое знание равноправно можно выразить в общем виде с использованием концептуальных схем, в количественной форме таблиц данных и символическим способом – формулами и алгоритмами математики.

На следующем уровне множество интертеорий дает возможность сквозным образом исследовать экономические объекты как системы разного рода. Аксиоматическое строение интертеории воспроизводит формальную структуру слоя расслоенного пространства знаний с выделением нормативных и позитивных законов существования и действия в хозяйственной сфере. Все интертеории взаимно интерпретируемы через замену понятий в их аксиомах, что позволяет переходить от одной теории к другой, создавать новые теории.

Специальные теории в рамках интертеории исследуют экономическую практику на примере типовых моделей отдельных объектов экономики, вводя в рассмотрение идентификаторы внутренних характеристик процессов. Экономические явления описываются не одной теорией, а полисистемной теорией разной формы и содержания с использованием соответствующей системы понятий, в координатах которой параметризуются данные об объектах наблюдения.

Разработанная схема не только осуществляет иерархическую классификацию знаний, но предлагает новые методы постановки и решения задач, системного анализа и математического моделирования экономических систем, что необходимо для развития экономической науки, совершенствования практики применения и преподавания знаний. Классификация будет полезна для идентификации знаний, их организации и оценки новизны.

**Благодарности.** Исследование выполнено за счет средств государственного задания Института географии им. В.Б. Сочавы СО РАН (№ 126020516555-4).

#### Список источников

1. Баликоев В.З. Экономические исследования: история, теория, методология / В.З. Баликоев. – М.: ИНФРА-М, 2023. – 349 с.
2. Баликоев В.З. Классификация экономических наук / В.З. Баликоев // Наука и социум. Материалы Всероссийской научно-практической конференции с международным участием: в 2 ч. – Новосибирск: Изд-во Сиб. института ПППиСР, 2019. – Ч. 2. – С. 112–116.
3. Vogrinčić S., Bosnić Z. Ontology-based multi-label classification of economic articles. Computer Science and Information Systems, 2011, vol. 8, no. 1, pp. 101–119, DOI:10.2298/CSIS100420034V.

4. Массель Л.В. Фрактальный подход к структурированию знаний и примеры его применения / Л.В. Массель // *Онтология проектирования*. – 2016. – Т.6, № 2 (20). – С. 149-161. – DOI: 10.18287/2223-9537-2016-6-2-149-161.
5. Salatino A.A., Thanapalasingam T., Mannocci A., et al. The computer science ontology: A comprehensive automatically-generated taxonomy of research areas. *Data Intelligence*, 2020, vol. 2, no. 3, pp. 379–416, DOI:10.1162/dint\_a\_00055.
6. Попов Е.В. Классификация экономической науки / Е.В. Попов // *Вестник УГТУ-УПИ*. – 2002. – № 2. – С. 23–31. – URL: <https://cyberleninka.ru/article/n/klassifikatsiya-ekonomicheskoy-nauki-1.pdf> (дата обращения: 27.10.2025).
7. Петрова С. Представяне на икономическите науки в различни класификационни схеми / С. Петрова, П. Петров // *Известия на съюза на учените*. – Варна, 2017. – № 2. – С. 267–276.
8. Ананьин О.И. Структура экономико-теоретического знания: методологический анализ / О.И. Ананьин. – М.: Наука, 2005. – 243 с.
9. Ананьин О.И. Экономика: наука и/или искусство / О.И. Ананьин // *Вопросы экономики*. – 2007. – № 11. – С. 4–24.
10. Ананьин О.И. Экономическая наука: вызов фрагментации. Сегментация экономической науки и проблемы синтеза / О.И. Ананьин // *Сборник материалов IV Октябрьской международной научной конференции по проблемам теоретической экономики*, 19–20 октября 2022 г. – СПб.: Алетейя, 2024. – С. 27–50.
11. Kincaid H., Ross D. (eds.) *Oxford handbook of philosophy of economics*. Oxford: Oxford University Press, 2009, 670 p.
12. Клейнер Г.Б. Расширяющаяся вселенная экономической теории / Г.Б. Клейнер // *Altereconomics*. – 2023. – Т. 20. – № 1. – С. 1–8. – DOI: 10.31063/AlterEconomics/2023.20-1.1.
13. Полтерович В.М. Кризис экономической теории / В.М. Полтерович // *Экономическая наука современной России*. – 1998. – № 1. – С. 46–66.
14. Балацкий Е.В. Новые императивы экономического знания: на пути к социомике / Е.В. Балацкий // *Социальное пространство*. – 2022. – Т. 8. – № 4. – DOI: 10.15838/sa.2022.4.36.2.
15. Клейнер Г.Б. Принципы двойственности в свете системной экономической теории / Г.Б. Клейнер // *Вопросы экономики*. – 2019. – № 11. – С. 127–149. – DOI: 10.32609/0042-8736-2019-11-127-149.
16. Клейнер Г.Б. Экономико-математическое моделирование и экономическая теория / Г.Б. Клейнер // *Экономика и математические методы*. – 2001. – Т. 37. – № 3. – С. 111–126.
17. Fanelli D., Glänzel W. Bibliometric Evidence for a Hierarchy of the Sciences. *PLoS ONE*, 2013, vol. 8(6), art. e66938, DOI: 10.1371/journal.pone.0066938.
18. Cole S. The hierarchy of the sciences? *American Journal of Sociology*, 1983, vol. 89, pp. 111–139.
19. Вечканов Г.С. Экономическая теория / Г.С. Вечканов. – СПб.: Питер, 2015. – 512 с.
20. Черкашин А.К. Классификация геосистем: аксиоматический подход / А.К. Черкашин // *Известия Иркутского государственного университета. Серия Науки о Земле*. – 2023. – Т. 43. – С. 102–126. – DOI: 10.26516/2073-3402.2023.43.102.
21. Campbell D.T. *Ethnocentrism of Disciplines and the Fish-Scale Model of Omniscience. Interdisciplinary collaboration: An emerging cognitive science*. Mahwah, NJ: Lawrence Erlbaum Associates Publishers, 2005, pp. 3–21.
22. Черкашин А.К. Особенности моделирования механизмов устойчивого развития / А.К. Черкашин // *Экономика и математические методы*, 2025. – Т. 61. – № 3. – С. 92-104.
23. Анучин В.А. Теоретические проблемы географии / В.А. Анучин. – М.: Гос. изд-во географ. литературы, 1960. – 264 с.
24. Баликоев В.З. *Общая экономическая теория* / В.З. Баликоев. – М.: Омега-Л; Новосибирск: Сибирское соглашение, 2008. – 732 с.
25. Черкашин А.К. *Полисистемный анализ и синтез* / А.К. Черкашин. – Новосибирск: Наука, 1997. – 502 с.
26. Корнай Я. Системная парадигма / Я. Корнай // *Вопросы экономики*, 2002. – № 4. – С. 4–22.
27. Клейнер Г.Б. Системная экономика как платформа развития современной экономической теории / Г.Б. Клейнер // *Вопросы экономики*, 2013. – № 6. – С. 4–28.
28. Клейнер Г.Б. Исследовательские перспективы и управленческие горизонты системной экономики / Г.Б. Клейнер // *Управленческие науки*, 2015. – № 4. – С. 7–20.
29. Черкашин А.К. Математические основания синтеза знаний междисциплинарных исследований социально-экономических явлений / А.К. Черкашин // *Журнал экономической теории*, 2017. – № 3. – С. 108–124.
30. Hjørland B. Facet analysis: The logical approach to knowledge organization. *Information Processing & Management*, 2013, vol. 49, no. 2, pp. 545–557, DOI: 10.1016/j.ipm.2012.10.001.

**Черкашин Александр Константинович.** Доктор географических наук, профессор, главный научный сотрудник лаборатории теоретической географии Института географии им. В.Б. Сочавы СО РАН. AuthorID:

UDC 005:51-7:330

DOI:10.25729/ESI.2026.42.2.001

## Hierarchical classification of economic knowledge

Aleksander K. Cherkashin

V.B. Sochava Institute of Geography SB RAS, Russia, Irkutsk, akcherk@irnok.net

**Abstract.** The natural classification of scientific knowledge has always been a challenging task. Its resolution would enable the organization of existing knowledge and facilitate the extraction of new insights for research, practical application, and education. This is particularly important in economics, which is seeing a proliferation of new fields that study national economic development using modern methods of systems analysis and mathematical modeling. This paper proposes a triadic classification scheme based on the principle of fractal similarity, which allows the entire structure to be replicated at every taxonomic level. Within this scheme, only typological units are treated as disjoint layers of knowledge; all other knowledge groups constitute combinations or combinatorial associations of these independent layers. To articulate this structure, we employ stratification procedures from differential geometry, separating information into distinct layers with different contents. The hierarchical classification comprises several levels, progressing from simple to complex and from abstract to concrete: data, concepts, models, intertheories, metatheories, and metascience (exemplified by mathematics). The metatheory level is divided into three sectors – general, quantitative, and formal knowledge – which correspond to political economy, financial analysis, and mathematical (digital) analysis, respectively. These sectors account for the economy's linkages with the external and internal environments of business entities. In a cross-cutting manner, intertheories describe phenomena in both nature and society as specific types of systems using a uniform terminology. On this basis, models of various economic entities – including enterprises in the energy sector – can be constructed. The data and knowledge representation space are defined by eight independent coordinates, one of which is economic growth. This framework underscores the independent meaning of economic knowledge, distinguishing it from that of other sciences.

**Keywords:** classification of scientific knowledge, economic theory, fractal hierarchy, metatheories and intertheories, basic concepts, mathematical modeling, digital economy

**Acknowledgements:** This study was carried out using funds from the State Task of the Sochava Institute of Geography, Siberian Branch, Russian Academy of Sciences (№ 126020516555-4).

### References

1. Balikoev V.Z. Ekonomicheskie issledovaniya: istoriya, teoriya, metodologiya [Economic research: history, theory, methodology]. Moscow: INFRA-M Publ., 2023, 349 p.
2. Balikoev V.Z. Klassifikatsiya ekonomicheskikh nauk [Classification of economic sciences]. Nauka i sotsium. Materialy Vserossiyskoy nauchno-prakticheskoy konferentsii s mezhdunarodnym uchastiem: v 2 ch. Novosibirsk: Izd-vo Sib. instituta PPPiSR Publ., 2019, Ch. 2, pp. 112–116.
3. Vogrinčič S., Bosnić Z. Ontology-based multi-label classification of economic articles. Computer Science and Information Systems, 2011, vol. 8, no. 1, pp. 101–119, DOI: 10.2298/CSIS100420034V.
4. Massel' L.V. Fraktal'nyj podkhod k strukturirovaniyu znaniy i primery ego primeneniya [Fractal approach to knowledge structuring and examples of its application]. Ontologiya proektirovaniya, 2016, vol. 6, no. 2 (20), pp. 149–161, DOI: 10.18287/2223-9537-2016-6-2-149-161.
5. Salatino A.A., Thanapalasingam T., Mannocci A. et al. The computer science ontology: A comprehensive automatically-generated taxonomy of research areas. Data Intelligence, 2020, vol. 2, no. 3, pp. 379–416, DOI:10.1162/dint\_a\_00055.
6. Popov E.V. Klassifikatsiya ekonomicheskoy nauki [Classification of economic science]. Vestnik UGTU-UPI, 2002, no. 2, pp. 23–31, available at: <https://cyberleninka.ru/article/n/klassifikatsiya-ekonomicheskoy-nauki-1.pdf> (accessed: 27.10.2025).
7. Petrova S., Petrov P. Predstavlyane na ikonomicheskite nauki v razlichni klasifikatsionni shemi [Representation of economic sciences in different classification schemes]. Izvestiya na sayuza na uchenite, Varna, 2017, no. 2, pp. 267–276.
8. Anan'in O.I. Struktura ekonomiko-teoreticheskogo znaniya: metodologicheskii analiz [The structure of economic-theoretical knowledge: a methodological analysis]. Moscow: Nauka Publ., 2005, 243 p.

9. Anan'in O.I. Ekonomika: nauka i/ili iskusstvo [Economics: science and/or art]. Voprosy ekonomiki, 2007, no. 11, pp. 4–24.
10. Anan'in O.I. Ekonomicheskaya nauka: vyzov fragmentatsii. Segmentatsiya ekonomicheskoy nauki i problemy sinteza [Economic science: the challenge of fragmentation. Segmentation of economic science and problems of synthesis]. Sbornik materialov IV Oktyabr'skoy mezhdunarodnoy nauchnoy konferentsii po problemam teoreticheskoy ekonomiki, 19–20 oktyabrya 2022 g. Saint Petersburg: Aleteyya Publ., 2024, pp. 27–50.
11. Kincaid H., Ross D. (eds.) Oxford handbook of philosophy of economics. Oxford: Oxford University Press, 2009, 670 p.
12. Kleyner G.B. Rasshiryayushchayasya vseennaya ekonomicheskoy teorii [The expanding universe of economic theory]. Altereconomics, 2023, vol. 20, no. 1, pp. 1–8, DOI: 10.31063/AlterEconomics/2023.20-1.1.
13. Polterovich V.M. Krizis ekonomicheskoy teorii [The crisis of economic theory]. Ekonomicheskaya nauka sovremennoy Rossii, 1998, no. 1, pp. 46–66.
14. Balatskiy E.V. Novye imperativy ekonomicheskogo znaniya: na puti k sotsionomike [New imperatives of economic knowledge: on the way to socionomics]. Sotsial'noe prostranstvo, 2022, vol. 8, no. 4, DOI: 10.15838/sa.2022.4.36.2.
15. Kleyner G.B. Printsipy dvoystvennosti v svete sistemnoy ekonomicheskoy teorii [Duality principles in the light of system economic theory]. Voprosy ekonomiki, 2019, no. 11, pp. 127–149, DOI: 10.32609/0042-8736-2019-11-127-149,
16. Kleyner G.B. Ekonomiko-matematicheskoe modelirovanie i ekonomicheskaya teoriya [Economic-mathematical modeling and economic theory]. Ekonomika i matematicheskie metody, 2001, vol. 37, no. 3, pp. 111–126.
17. Fanelli D., Glänzel W. Bibliometric Evidence for a Hierarchy of the Sciences. PLoS ONE, 2013, vol. 8(6), art. e66938. DOI: 10.1371/journal.pone.0066938.
18. Cole S. The hierarchy of the sciences? American Journal of Sociology, 1983, vol. 89, pp. 111–139.
19. Vechkanov G.S. Ekonomicheskaya teoriya [Economic theory]. Saint Petersburg: Piter Publ., 2015, 512 p.
20. Cherkashin A.K. Klassifikatsiya geosistem: aksiomaticheskij podkhod [Classification of geosystems: an axiomatic approach]. Izvestiya Irkutskogo gosudarstvennogo universiteta. Seriya Nauki o Zemle, 2023, vol. 43, pp. 102–126. DOI: 10.26516/2073-3402.2023.43.102.
21. Campbell D.T. Ethnocentrism of Disciplines and the Fish-Scale Model of Omniscience. Interdisciplinary collaboration: An emerging cognitive science. Mahwah, NJ: Lawrence Erlbaum Associates Publishers, 2005, pp. 3–21.
22. Cherkashin A.K. Osobennosti modelirovaniya mekhanizmov ustoychivogo razvitiya [Features of modeling sustainable development mechanisms]. Ekonomika i matematicheskie metody [Economics and Mathematical Methods], 2025, vol. 61, no. 3, pp. 92–104.
23. Anuchin V.A. Teoreticheskiye problemy geografii [Theoretical Problems of Geography]. Moscow, Gos. izd-vo geograf. literatury [State Publishing House of Geographical Literature] Publ., 1960, 264 p.
24. Balikoev V.Z. Obshchaya ekonomicheskaya teoriya [General Economic Theory]. Moscow, Omega-L Publ.; Novosibirsk, Sibirskoye soglasheniye [Siberian Agreement] Publ., 2008, 732 p.
25. Cherkashin A.K. Polissistemnyy analiz i sintez [Polysystem Analysis and Synthesis]. Novosibirsk, Nauka [Science] Publ., 1997, 502 p.
26. Kornai J. Sistemnaya paradigma [System paradigm]. Voprosy ekonomiki [Economic Issues], 2002, no. 4, pp. 4–22.
27. Kleiner G.B. Sistemnaya ekonomika kak platforma razvitiya sovremennoy ekonomicheskoy teorii [System economy as a platform for the development of modern economic theory]. Voprosy ekonomiki [Economic Issues], 2013, no. 6, pp. 4–28.
28. Kleiner G.B. Issledovatel'skiye perspektivy i upravlencheskiye gorizonty sistemnoy ekonomiki [Research perspectives and management horizons of system economy]. Upravlencheskiye nauki [Management Sciences], 2015, no. 4, pp. 7–20.
29. Cherkashin A.K. Matematicheskiye osnovaniya sinteza znaniy mezhdistsiplinarynykh issledovaniy sotsial'no-ekonomicheskikh yavleniy [Mathematical foundations for the synthesis of knowledge in interdisciplinary studies of socio-economic phenomena]. Zhurnal ekonomicheskoy teorii [Journal of Economic Theory], 2017, no. 3, pp. 108–124.
30. Hjørland B. Facet analysis: The logical approach to knowledge organization. Information Processing & Management, 2013, vol. 49, no. 2, pp. 545–557, DOI: 10.1016/j.ipm.2012.10.001.

**Cherkashin Aleksander Konstantinovich.** Doctor of geographical sciences, professor, chief researcher of the laboratory of Theoretical geography of V.B. Sochava Institute of Geography SB RAS, AuthorID: 58425, SPIN: 5266-0499, ORCID: 0000-0002-7596-7780, WOS: K-2418-2017, akcherk@irnok.net, 664033, Irkutsk, Ulaanbaatar st. 1.

Статья поступила в редакцию 28.10.2025; одобрена после рецензирования 16.04.2026; принята к публикации 12.05.2026.

The article was submitted 10/28/2025; approved after reviewing 04/16/2026; accepted for publication 05/12/2026.

## Формирование универсального навыка рефлексии в условиях предельных моделей мира

Маркова Галия Муратовна<sup>1,2</sup>, Барцев Сергей Игоревич<sup>1,2</sup>

<sup>1</sup>Институт биофизики СО РАН – обособленное подразделение ФИЦ КНЦ СО РАН, Россия, Красноярск, *GMarkova@ibp.ru*

<sup>2</sup>Институт фундаментальной биологии и биотехнологий, Сибирский федеральный университет, Россия, Красноярск

**Аннотация.** Выживание в изменчивой среде – задача, для решения которой необходимо выявлять и запоминать наиболее существенные закономерности среды, а также действовать с их учетом. Способность организма или агента, имитирующего организм, формировать и использовать представления о внешней среде, мы называем рефлексией в широком смысле. Статья посвящена выявлению связи между предсказуемостью событий в среде и возникновением универсального навыка рефлексии у агентов в этой среде. В качестве агентов используются эвристические модельные объекты – простые рекуррентные нейронные сети, первичное обучение которых проводится в условиях предельных моделей мира. Данные модели реализуются, как задачи: реагирование на случайную последовательность стимулов, рефлексивная игра, реагирование на набор фиксированных последовательностей и реагирование на единственную фиксированную последовательность. Возникновение универсального навыка рефлексии после первичного обучения каждой из этих задач оценивается по качеству отклика обученных модельных объектов в проверочных задачах. Также оцениваются максимальное собственное значение Якобиана матрицы весов сети и тип траектории нейронной активности после иницилирующего одиночного стимула. По совокупности характеристик, в наибольшей степени формированию универсального навыка рефлексии способствуют модели мира с предзаданной периодичностью событий (стимулов). Напротив, в условиях труднопредсказуемой среды возникновение внутренних представлений о мире оказывается затруднено. Полученные результаты позволяют систематизировать представление о рефлексии в широком смысле и упростить выбор условий среды для дальнейших исследований данного явления.

**Ключевые слова:** рефлексия, простая рекуррентная нейронная сеть, рефлексивные игры, реагирование на последовательности стимулов, предельная модель мира

**Цитирование:** Маркова Г.М. Формирование универсального навыка рефлексии в условиях предельных моделей мира / Г.М. Маркова, С.И. Барцев // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 18-28. – DOI:10.25729/ESI.2026.42.2.002.

**Введение.** Жизнь любого организма связана с освоением окружающей его среды [1-5]. Под освоением в данном случае подразумевается, что организму необходимо выявить и запомнить наиболее существенные для выживания закономерности среды, а также научиться действовать в соответствии с этими закономерностями [6]. Иными словами, необходимо сформировать представление о среде и использовать его для достижения цели [7], которая в общем случае представляет собой выживание. Представление о среде, или репрезентация внешнего мира, является необходимым для реализации когнитивной функции, которую мы, вдохновляясь трудами В.А. Лефевра [8], называем рефлексией в широком смысле.

Формирование репрезентации внешнего мира связано с предсказанием событий [1, 5]. Репрезентации, в сущности, необходимы для того, чтобы живущий в среде организм мог предсказывать ее события и выбирать поведение, наиболее адекватное ситуации, с выгодой для выживания. В труднопредсказуемой среде организмы формируют иные стратегии поведения, чем в предсказуемой [9], которые могут включать более агрессивное или импульсивное поведение [10], также возможны изменения в когнитивных функциях [11].

Настоящая статья посвящена вопросу о том, как предсказуемость событий в среде, первично осваиваемой агентом, влияет на формирование рефлексии в широком смысле, как универсального навыка, с помощью которого агент может запоминать и распознавать

паттерны событий внешнего мира, ранее ему неизвестные, а также формировать правильный поведенческий отклик.

**1. Эвристическое нейросетевое моделирование рефлексии в рамках предельных моделей мира.** С позиций биофизического подхода наиболее общие функции, присущие живым организмам, могут быть воспроизведены и исследованы на объектах другого типа, например, искусственных нейронных сетях [12, 13]. Мы воспроизводим функцию рефлексии с помощью эвристического (по фон Нейману [14]) нейросетевого моделирования, что позволяет выявлять наиболее общие закономерности исследуемого феномена. Применимость объектов такого типа для моделирования рефлексии обоснована в наших работах [15, 16]. Мы используем нейронные сети малых размеров (30 нейронов) и простейшей рекуррентной структуры, т.к. рекуррентность важна для когнитивных феноменов [17, 18].

Для формирования репрезентаций внешнего мира необходимо поместить эвристический модельный объект (рекуррентную нейронную сеть, РНС) в соответствующую среду. Следуя, как было упомянуто выше, биофизическому подходу, мы выделяем линейку абстрактных моделей мира, предельных с точки зрения информационного взаимодействия: среда случайных событий, среда-соперник, среда кусочно-регулярных (по Клини [19]) событий, среда полностью регулярных событий. Общее их свойство – наличие потока дискретных событий (стимулов), которые предъявляются модельному объекту, и он должен сформировать на каждое отклик, адекватность которого оценивается по заранее заданному правилу. Набор возможных событий для каждой модели мира также задается заранее. В таком случае модель мира может задаваться, как условия некоторой задачи.

*Среда полностью регулярных событий* представляет собой последовательное предъявление РНС одной фиксированной последовательности стимулов, что является примером абсолютно предсказуемого окружения, где освоение правильного поведенческого паттерна, которому будет соответствовать определенное внутреннее представление – лишь вопрос времени. *Среда кусочно-регулярных (т.е. периодически воспроизводимых) событий*, по сравнению с полностью регулярной менее предсказуема: РНС предъявляются в определенном порядке несколько фиксированных последовательностей стимулов (временных рядов), и задача сводится не только к реагированию, но и распознаванию ряда при его подаче, что требует наличия у РНС внутренних представлений для каждого ряда [20, 21]. *Среда-соперник* представляет собой мир, который «уклоняется» от попыток предсказать его события и потому избегает фиксированных последовательностей. Условия такого мира могут быть представлены, как рефлексивная игра, где противник РНС – другая РНС [22], либо иной объект, например, машина Шеннона [23]. Наконец, в *предельно непредсказуемой среде* события, предъявляемые РНС, выбираются из имеющегося набора случайным образом. В рамках такого мира вопрос о правильном поведенческом паттерне лишен смысла (если не задаваться целью «раскусить» алгоритм генератора случайных чисел), и интерес представляет равновесное состояние, в которое придет РНС в итоге «освоения» такого мира.

**1.1. Цель работы.** Работа посвящена проверке того, возникает ли универсальный навык рефлексии в широком смысле у эвристических модельных объектов – РНС – в результате освоения задач, представляющих собой предельные модели мира. Проверка производилась путем первичного обучения РНС одной из этих задач и тестирования на других. Ожидалось, что если универсальный навык рефлексии был сформирован, то при тестировании в новой, ранее неизвестной задаче РНС продемонстрируют результат как минимум не хуже, чем РНС, изначально обученные на этой задаче. Оценивались формальная, структурная и нейронная характеристики РНС после освоения первичных задач, что позволило получить наиболее полное представление о том, как условия предельной модели мира влияют на способность

модельного объекта к предсказанию событий среды. Описание исследуемых характеристик представлено в разделе 2.1.

**2. Обучение и тестирование РНС.** Мы использовали простые гомогенные 30-нейронные РНС, функционирование которых в дискретном режиме описывается формулами:

$$\alpha_i^{n+1} = \frac{\rho_i^n}{a + |\rho_i^n|}, \rho_i^n = \sum_j w_{ij} \alpha_j^n + A_i^n, \quad (1)$$

где  $\alpha_j^n$  – выходной сигнал  $j$ -го нейрона на  $n$ -ом такте;  $w_{ij}$  – матрица весовых коэффициентов РНС;  $A_i^n$  – входной сигнал, поданный на  $i$ -ый нейрон на  $n$ -ом такте;  $a$  – константа, определяющая крутизну переходной характеристики нейрона. Начальные веса РНС задавались случайным образом в диапазоне  $(-0.025; 0.025)$ . РНС данного типа использовались нами в предыдущих работах [15, 16, 20, 22].

Мы проводили первичное обучение РНС одной из задач: реагирование на случайную последовательность стимулов, рефлексивная игра, реагирование на фиксированные временные ряды стимулов (кратко – ряды), реагирование на единственную фиксированную последовательность стимулов (кратко – регулярную последовательность). Правильность откликов РНС определялась по двум вариантам правил: соответствующим игре чет-нечет (ЧН) и камень-ножницы-бумага (КНБ).

По правилам ЧН, возможны два хода: «0» и «1», а задача РНС – сделать тот же ход на текущем такте, что и противник, т.е. РНС играли за позицию «чет». Если на предыдущем такте противник выбрал отклик «0», то на текущем такте он подавался как стимулы 01 на два входа РНС, если «1» – как 10. Отклик РНС определялся по соотношению сигналов на двух выходных нейронах. По правилам КНБ, возможны три хода: «0», «1», «2», которые подавались, как стимулы на три входа РНС как 001, 010 и 100. Отклик РНС определялся аналогично правилам ЧН, задача РНС – сделать ход, побеждающий ход противника на текущем такте.

В задаче реагирования на временные ряды стимулов мы использовали 4 ряда с повторяющимися сегментами длины 6 (например, 101001), сгенерированные с помощью генератора случайных чисел единожды перед запуском обучения. Через каждые 60 тактов происходило переключение с одного ряда на другой, в одном и том же порядке. В рефлексивных играх противниками РНС были РНС той же конфигурации и размера. В реагировании на регулярную последовательность мы использовали один ряд с сегментом длины 24, что эквивалентно суммарному размеру вышеописанных 4 рядов с сегментами длины 6. Данная последовательность генерировалась случайно перед началом обучения. Наконец, в задаче реагирования на случайную последовательность каждый последующий стимул также генерировался случайно.

Продолжительность первичного обучения составляла максимально 100 000 тактов, что для выбранных РНС и задач рассматривается, как достаточно долгое, при котором возможен выход динамической системы на устойчивое состояние. Обучение РНС происходило по широко известному алгоритму backpropagation с глубиной распространения 5 тактов, использовалась квадратичная функция потерь.

В качестве проверочных задач мы использовали только рефлексивные игры и реагирование на ряды, поскольку из четырех рассматриваемых в настоящей работе задач именно их можно в полной мере считать задачами на рефлекссию, т.е. такими, где формирование внутренних представлений необходимо для успешного решения. Тест наличия универсального навыка мы проводили, сохраняя возможность модифицировать матрицу весов РНС, что, во-первых, позволяет оценить возможности РНС к адаптации к новым условиям после длительного первичного обучения, а во-вторых – биологически правдоподобно. В проверочных задачах ряды и РНС-противники генерировались заново. Тест проводился в течение 500 тактов.

**2.1. Исследуемые характеристики РНС.** Мы оценивали качество отклика РНС, как долю правильных откликов за весь тест – отношение количества «победных» тактов (согласно правилам ЧН или КНБ) к их общему количеству. Результаты РНС в проверочных задачах мы сопоставляли с таковыми у контрольной группы РНС того же размера и конфигурации, но не обученных никаким задачам, которые проходили проверку сразу после генерации весов. Во всех группах использовалось по 100 РНС. Данная характеристика названа *формальной*, т.к. отражает только результат тестирования, а не внутренние свойства РНС.

Реализация любой функции обеспечивается определенной структурой. Оценить поведение системы в стационарном состоянии (т.е. по прошествии достаточно длительного времени) с помощью структурных параметров возможно при рассмотрении такой характеристики, как максимальное собственное значение Якобиана (МСЯ) правой части уравнений, описывающих функционирование системы. Так, для уравнений, задающих функционирование РНС (1), элемент Якобиана для стационарного состояния имеет следующий вид:

$$J_{ij} = \frac{1}{a}(1 - |\bar{\alpha}_i|)^2 w_{ij}, \quad (2)$$

где  $a$  – крутизна переходной характеристики нейронов РНС,  $\alpha_i$  – сигнал на  $i$ -том нейроне,  $w_{ij}$  – текущий элемент матрицы весов РНС.

Расчет МСЯ позволяет определить, является ли невозбужденное состояние РНС ( $\alpha_i = 0$  для всех  $0 \leq i \leq N$ , где  $N$  – количество нейронов РНС) устойчивым. В этом случае элемент Якобиана имеет простой вид:

$$J_{ij} = \frac{1}{a} w_{ij}. \quad (3)$$

По формуле (3) видим, что сам Якобиан, как и его собственные значения, зависят от весов РНС, следовательно, они изменяются в ходе обучения РНС, когда происходит модификация весов. Мы использовали максимальные МСЯ, взятые по модулю, для оценки структурного сходства РНС, рассматривая при этом значения при продолжительности обучения 0, 500, 1000, 3000, 5000, 10 000, 30 000, 50 000, 100 000 тактов, и усредняя данный показатель по 100 РНС для каждой продолжительности. Данная характеристика названа *структурной*.


Доли правильных откликов РНС и величины МСЯ соответствуют нормальному распределению, что было проверено с помощью критерия Пирсона (хи-квадрат),  $\alpha=0,95$ . Поэтому для описания этих величин использовались средние значения и стандартные отклонения ( $m \pm SD$ ), а для определения значимости различий между выборками применялся параметрический двухсторонний t-тест с различными дисперсиями ( $\alpha=0,05$ ).

Также рассматривалась *нейрональная* характеристика – доля РНС с определенным типом свободного аттрактора нейронной активности. Аттрактор нейронной активности – траектория в многомерном пространстве, где координаты точек представлены сигналами на нейронах РНС на текущем такте. Под свободным аттрактором подразумевается траектория нейронной активности, которая возникает у РНС после подачи иницирующего одиночного стимула «0». У РНС могут формироваться траектории следующих типов: затухающая (устойчивая нулевая точка), циклическая, устойчивая ненулевая точка, странная (квазихаотическая) [22].

Генерация, обучение и тестирование РНС проводились в среде разработки Lazarus (<https://www.lazarus-ide.org/>).

**3. Результаты и обсуждение.** В этом разделе представлены оценки формальной, нейрональной и структурной характеристик РНС.

**3.1. Формальная характеристика РНС.** После освоения первичных задач РНС были протестированы в проверочных задачах на рефлексивную игру и реагировании на ряды. Доли правильных откликов РНС в проверочных задачах приведены на Рис. 1.



**Рис. 1.** Доли правильных откликов РНС, первично обученных в разных задачах, при тесте на проверочных задачах: ряды и игра по правилам ЧН либо КНБ. Контрольная группа – необученные РНС того же размера и конфигурации. Здесь и далее погрешности – стандартное отклонение


РНС, первично обученные реагированию на ряды и регулярную последовательность, на проверочных задачах продемонстрировали лучшие результаты, сопоставимые с таковыми у контрольной группы (Рис. 1, серые и желтые столбцы). Данный факт свидетельствует о том, что эти РНС не утратили способность к адаптации, в отличие от РНС, обученных играм и реагированию на случайную последовательность (Рис. 1, оранжевые и голубые столбцы), т.к. их результаты в основном значимо хуже, чем у контрольной группы.

В проверочных задачах рефлексивной игры КНБ и реагирования на ряды по обоим правилам РНС, которые были обучены на случайной последовательности стимулов (Рис.1, голубые столбцы), продемонстрировали результаты значимо хуже прочих РНС. Исключение составляет проверочная задача игры ЧН, где РНС, обученные на случайной последовательности, продемонстрировали тот же средний результат, что и контрольная группа – необученные РНС (Рис. 1, темно-синие столбцы). Интересно, что РНС, первично обученные игре ЧН (Рис.1, оранжевые столбцы), при тестировании на этой же проверочной задаче показали наихудший средний результат среди всех РНС, притом значимо хуже, чем обученные на случайной последовательности. Возможное объяснение состоит в том, что РНС, обученные игре ЧН, сохраняют чувствительность ко входным данным, однако делают при этом ошибки, а РНС, обученные на случайной последовательности, демонстрируют в игре ЧН формально более высокую, но при этом «равновесную» долю правильных откликов 50%, поскольку выдают серии откликов типа «000...» или «111...», т.е. не обладают чувствительностью к получаемым на вход стимулам. В игре КНБ «равновесная» доля составляет около 33%, что и наблюдается (Рис. 1).

Наконец, отметим, что РНС, первично обученные реагированию на ряды и регулярную последовательность, на проверочных задачах продемонстрировали во всех проверочных задачах значимо более высокие доли правильных откликов, чем первично обученные играм, даже в тех случаях, где проверочной задачей была игра. Следовательно, условия предельных

моделей мира с предзаданной повторяемостью событий оказываются более подходящими для формирования универсального навыка рефлексии.

**3.2. Нейронная характеристика РНС.** После обучения первичным задачам были определены доли РНС с различными типами свободного аттрактора после подачи одиночного иницирующего стимула, что характеризует динамику внутреннего состояния РНС (Рис. 2).



**Рис. 2.** Доли РНС с разными типами траекторий нейронной активности после одиночного иницирующего стимула, обученных с разной продолжительностью в задачах: игры ЧН и КНБ; реагирование на ряды по правилам ЧН и КНБ; реагирование на случайные последовательности по правилам ЧН и КНБ; реагирование на регулярную последовательность по правилам ЧН и КНБ

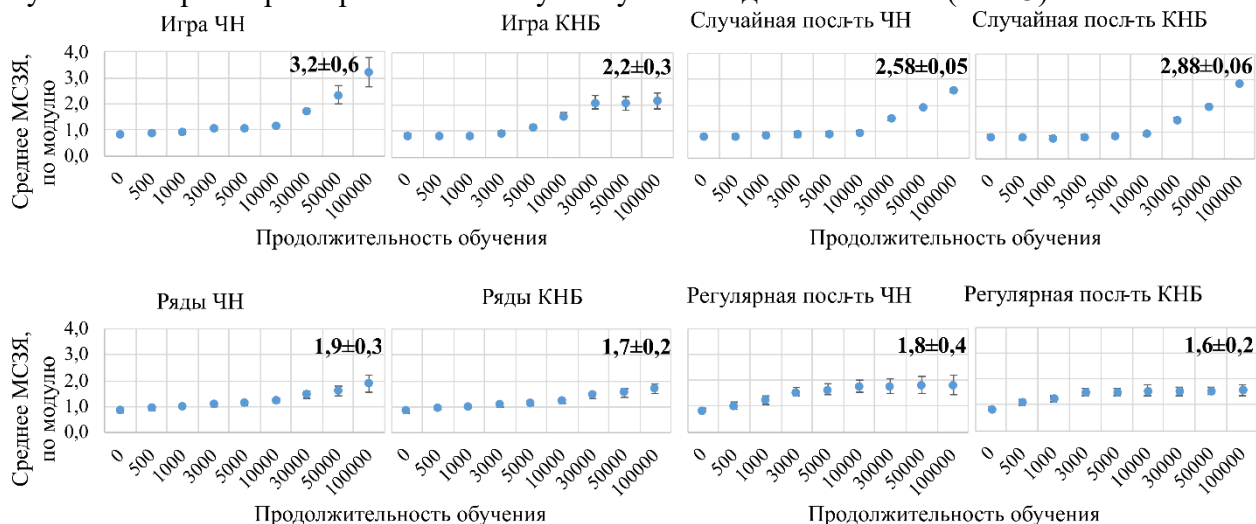
Распределения по долям РНС с разными типами свободных аттракторов после обучения на играх ЧН и КНБ оказались непохожими, несмотря на формальное сходство задач (обе – рефлексивные игры с равным по силе противником), в то время как после обучения другим задачам конкретные правила приводят к малым отличиям в долях РНС с разным типом аттракторов (Рис. 2). Также наблюдается некоторое сходство распределений у РНС после обучения на играх и на случайных последовательностях (особенно по правилам КНБ), так же, как и при обучении на рядах и регулярной последовательности.

После обучения на случайной последовательности в течение 100 000 тактов, в отличие от обучения на всех остальных задачах, странные аттракторы полностью отсутствуют (Рис. 2). Данный тип аттрактора связан с хранением информации о внешних стимулах в незатухающем паттерне нейронной активности [24, 25], что может рассматриваться как аналог рабочей памяти. РНС при продолжительном освоении мира случайных событий также формируют незатухающий паттерн, но другого типа – фиксированная ненулевая точка, который, в отличие от странного аттрактора, не характеризуется чувствительностью внутреннего состояния РНС к внешним стимулам. Внутреннее представление о мире, сформировавшееся у РНС в мире случайных событий, не подразумевает попытки предсказания последующего стимула, поэтому при тестировании данные РНС показывают низкий формальный результат (Рис. 1).

**3.3. Структурная характеристика РНС.** После обучения первичным задачам были рассчитаны абсолютные величины МСЯ, характеризующие матрицы весов РНС.

РНС, обученные реагированию на ряды и регулярную последовательность, как было показано на Рис. 1, демонстрируют лучшие результаты в проверочных задачах. Также эти РНС

после 100 000 тактов обучения обладают значимо меньшими по модулю средними МСЯ, чем обученные играм и реагированию на случайную последовательность (Рис. 3).



**Рис. 3.** Средние МСЯ, взятые по модулю, в зависимости от продолжительности обучения задачам: игры ЧН и КНБ; реагирование на ряды по правилам ЧН и КНБ; реагирование на случайные последовательности по правилам ЧН и КНБ; реагирование на регулярную последовательность по правилам ЧН и КНБ. На графиках подписаны итоговые МСЯ после 100 000 тактов обучения (среднее ± стандартное отклонение)

Величины МСЯ, как структурной характеристики РНС, позволяют сделать вывод, что освоение наиболее труднопредсказуемых сред, таких, как случайная среда и среда-соперник, приводит к нарастанию весовых коэффициентов РНС, что, в свою очередь, может затруднять адаптацию в проверочных задачах. Кусочно-регулярная или полностью регулярная среда, напротив, способствует наиболее быстрому освоению новой среды в рамках проверочной задачи, что свидетельствует о формировании у РНС, первично осваивавших такие среды, универсального навыка рефлексии. Неожиданность полученного результата заключается в том, что обучение в полностью регулярной среде не приводит к «жесткости» структуры РНС, которая могла бы помешать формированию правильного отклика в проверочных задачах. Более того, реагирование на регулярную последовательность – единственная задача, где для обоих правил (ЧН и КНБ) наблюдается выход средних абсолютных величин МСЯ на плато по мере увеличения продолжительности обучения (Рис. 3). Для сравнения, продолжительное обучение РНС реагированию на случайную последовательность и рефлексивным играм, напротив, приводят к росту МСЯ, что может объясняться нарастанием весов РНС при неизбежных ошибках вследствие труднопредсказуемости стимулов.

**3.4. Обсуждение.** Из полученных результатов следует, что наиболее важная характеристика потока событий в среде с точки зрения рефлексии – воспроизводимость (повторяемость), даже если длина повторяющегося сегмента довольно велика. Условия среды-соперника, которые мы моделировали в рамках рефлексивных игр, не содержат предзаданной воспроизводимости последовательностей стимулов-ходов соперника, но она может появиться в ходе игры самопроизвольно при выборе ходов РНС-игроками. Однако полученные нами результаты показывают, что данный процесс либо не происходит, либо его масштабы незначительны, так что условия среды, моделируемой в игре, остаются для РНС почти такими же непредсказуемыми, как случайная последовательность стимулов. Из-за этого формирование внутренних представлений о мире-противнике у РНС при освоении таких задач затрудняется, и наличия универсального навыка рефлексии при тестировании не наблюдается.

В свою очередь, регулярность событий среды способствует формированию внутренних представлений, благодаря чему происходит распознавание типичных паттернов событий и

правильный отклик [16, 20]. Даже если условия среды изменятся, как, например, при переходе от первичной задачи к проверочной, структура РНС уже организована для наиболее эффективного удержания внутренних представлений, например, с помощью сохранения актуальной информации в незатухающем паттерне нейронной активности даже при отсутствии внешних стимулов [24, 25]. Как было показано в настоящей работе, такой паттерн может быть представлен странными аттракторами в пространстве нейронной активности.

**Заключение.** По совокупности характеристик (формальная – доля правильных откликов в проверочной задаче, нейрональная – доля РНС со странным аттрактором после освоения первичной задачи, структурная – величина МСЯ после освоения первичной задачи), из рассмотренных предельных абстрактных сред кусочно-регулярная и полностью регулярная среда в наибольшей степени способствуют формированию универсального навыка рефлексии. Результат согласуется с данными о значимости регулярных событий для живых организмов, представленными в литературе [12, 26, 27]. Труднопредсказуемость событий внешнего мира рассматривается, как негативный стрессовый фактор, особенно на ранних этапах жизни [9-11].

Полученные результаты позволяют уточнить наше представление о рефлексии в широком смысле, основанной на внутренних представлениях внешнего мира, и упрощают выбор условий среды для дальнейших исследований данного явления.

#### Список источников

1. Conway Christopher M. How does the brain learn environmental structure? Ten core principles for understanding the neurocognitive mechanisms of statistical learning. *Neuroscience & Biobehavioral Reviews*, 2020, vol. 112, pp. 279–299, DOI: 10.1016/j.neubiorev.2020.01.032.
2. Friston K., et al. Active inference and learning. *Neuroscience & Biobehavioral Reviews*, 2016, vol. 68, pp. 862–879, DOI: 10.1016/j.neubiorev.2016.06.022.
3. Yu L.Q., Wilson R.C., Nassar Matthew R. Adaptive learning is structure learning in time. *Neuroscience & Biobehavioral Reviews*, 2021, vol. 128, pp. 270–281, DOI: 10.1016/j.neubiorev.2021.06.024.
4. Rouhani N., Murty V.P. Episodic contributions to predictive learning. *Neuroscience & Biobehavioral Reviews*, 2025, vol. 172, p. 106122, DOI: 10.1016/j.neubiorev.2025.106122.
5. Goekoop R., de Kleijn R. Hierarchical network structure as the source of hierarchical dynamics (power-law frequency spectra) in living and non-living systems: How state-trait continua (body plans, personalities) emerge from first principles in biophysics. *Neuroscience & Biobehavioral Reviews*, 2023, vol. 154, p. 105402, DOI: 10.1016/j.neubiorev.2023.105402.
6. Erdin O., Bickhard M.H. Representing is something that we do, not a structure that we “use”: Reply to Gładziejewski. *New Ideas in Psychology*, 2018, vol. 49, pp. 27–37. DOI: 10.1016/j.newideapsych.2018.02.001.
7. Verschure P.F. M.J., Pennartz C.M.A., Pezzulo G. The why, what, where, when and how of goal-directed choice: neuronal and computational principles. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2014, vol. 369, p. 20130483, DOI: 10.1098/rstb.2013.0483.
8. Lefebvre V.A. The fundamental structures of human reflexion, *Journal of Social and Biological Structures*, 1987, vol. 10, iss.2, pp. 129–175, DOI: 10.1016/0140-1750(87)90004-2.
9. Yang An T., Lu Hui J., Chang Lei Environmental harshness and unpredictability, parenting, and offspring life history. *Evolutionary Psychological Science*, 2023, vol. 9, no.4, pp. 451–462, DOI: 10.1007/s40806-023-00375-y.
10. Fenneman J., Frankenhuys W.E. Is impulsive behavior adaptive in harsh and unpredictable environments? A formal model. *Evolution and Human Behavior*, 2020, vol. 41, no.4, pp. 261–273, DOI: 10.1016/j.evolhumbehav.2020.02.005.
11. Pietto M.L., et al. Perceived levels of environmental unpredictability and changes in visual attention mechanisms in adults. *Behavioural Brain Research*, 2025, p. 115601, DOI: 10.1016/j.bbr.2025.115601.
12. Барцев С.И. Эвристические нейросетевые модели в биофизике: приложение к проблеме структурно-функционального соответствия / С.И. Барцев, О.Д. Барцева. – Красноярск: Сибирский федеральный университет, 2010. – 114 с.
13. Vaciu Dan C. Neural networks through the lens of evolutionary dynamics. *BioSystems*, 2025, vol. 248, p. 105386. DOI: 10.1016/j.biosystems.2024.105386.
14. Фон Нейман Дж. Теория самовоспроизводящихся автоматов / Дж. Фон Нейман – М.: Мир, 1971. – С. 382.

15. Барцев С.И. Биофизический подход к моделированию рефлексии: обоснование, методы, результаты / С.И. Барцев, Г.М. Маркова, А.И. Матвеева // *Философские проблемы информационных технологий и киберпространства*, 2023. – № 2. – С. 120–139. – DOI: 10.17726/philIT.2023.2.9.
16. Маркова Г.М. Предельно просто не значит предельно ясно: некоторые контринтуитивные результаты нейросетевого моделирования рефлексии / Г.М. Маркова, С.И. Барцев // *Информационные и математические технологии в науке и управлении*, 2025. – № 1 (37). – С. 5–15. – DOI: 10.25729/ESI.2025.37.1.001.
17. Kaplan H.S., Nichols A.L.A., Zimmer M. Sensorimotor integration in *Caenorhabditis elegans*: a reappraisal towards dynamic and distributed computations. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2018, vol. 373, no.1758, p. 20170371, DOI: 10.1098/rstb.2017.0371.
18. Lamme V.A.F. Challenges for theories of consciousness: seeing or knowing, the missing ingredient and how to deal with panpsychism. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2018, vol. 373, no.1755, p. 20170344, DOI: 10.1098/rstb.2017.0344.
19. Kleene S.C. Representation of events in nerve nets and finite automata. Shannon Claude E., McCarthy John *Automata Studies*. Princeton University Press, 1956, pp. 3–41.
20. Markova G.M., Bartsev S.I. Does a Recurrent Neural Network Form Recognizable Representations of a Fixed Event Series? *Advances in Neural Computation, Machine Learning, and Cognitive Research VII. NI 2023. Studies in Computational Intelligence*. Eds. Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tiumentsev Y., Klimov V. Springer, Cham, 2023, vol. 1120, pp. 206-213. DOI: 10.1007/978-3-031-44865-2\_23.
21. Markova G.M., Bartsev S.I. Decoding Neural Activity of the Simplest Heterogeneous Neural Networks, In: *Advances in Neural Computation, Machine Learning, and Cognitive Research VIII. NI 2024. Studies in Computational Intelligence*. Eds. Redko V., Yudin D., Dunin-Barkowski W., Kryzhanovsky B., Tiumentsev Y. Springer, Cham, 2025, vol. 1179, pp. 362-371. DOI: 10.1007/978-3-031-80463-2\_34.
22. Bartsev S.I., Markova G.M. Does a Recurrent Neural Network Use Reflection During a Reflexive Game? *Advances in Neural Computation, Machine Learning, and Cognitive Research VI. NI 2022. Studies in Computational Intelligence*. Eds. Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tiumentsev Y. Springer, Cham, 2023, v.1064, pp. 148-157. DOI: 10.1007/978-3-031-19032-2\_15.
23. Shannon C.E. A mind-reading machine. Bell Laboratories memorandum, 1953.
24. Johnston J.W., Fusi S. Abstract representations emerge naturally in neural networks trained to perform multiple tasks. *Nature Communications*, 2023, vol. 14, no.1, p. 1040, DOI: 10.1038/s41467-023-36583-0.
25. Stroud Jake P, Duncan John, Lengyel Mate The computational foundations of dynamic coding in working memory. *Trends in Cognitive Sciences*, 2024, vol. 28, iss.7, pp. 614-627, DOI: 10.1016/j.tics.2024.02.011.
26. Анохин П.К. Избранные труды: философские аспекты теории функциональных систем / П.К. Анохин – М.: Наука, 1978. – 400 с.
27. Kanaev A.I., Dryaeva E.D. The Evolutionary Pathway to Consciousness and Reason: the Cognitome from a Philosophical Perspective. *Neuroscience and Behavioral Physiology*, 2023, vol. 53, no.7, pp. 1146–1157, DOI: 10.1007/s11055-023-01511-8.

**Маркова Галия Муратовна.** Младший научный сотрудник Института биофизики СО РАН, ассистент кафедры биофизики Института фундаментальной биологии и биотехнологии СФУ. Основные направления исследований: нейросетевое моделирование когнитивных функций, нейроинформатика. AuthorID: 1075515, SPIN: 1664-7436, ORCID: 0000-0003-1726-8102, GMarkova@ibp.ru, 660036, Красноярск, ул. Академгородок, 50, стр. 50.

**Барцев Сергей Игоревич.** Доктор физико-математических наук, главный научный сотрудник Института биофизики СО РАН, заведующий лабораторией теоретической биофизики Института биофизики СО РАН, профессор кафедры биофизики Института фундаментальной биологии и биотехнологии СФУ. Основные направления исследований: нейросетевое моделирование когнитивных функций, нейроинформатика, малоразмерные биосферные модели, снижение сложности моделей биологических систем, проектирование биологических систем жизнеобеспечения для космического применения. AuthorID: 66068, SPIN: 1884-5876, ORCID: 0000-0003-0140-4894, BartsevSI@ibp.ru, 660036, Красноярск, ул. Академгородок, 50, стр. 50.

UDC 577.38+004.81

DOI:10.25729/ESI.2026.42.2.002

## Formation of a universal reflection skill in the conditions of the limit world models

Galiya M. Markova<sup>1,2</sup>, Sergey I. Bartsev<sup>1,2</sup>

<sup>1</sup>Institute of Biophysics Siberian Branch of RAS, Russia, Krasnoyarsk, *GMarkova@ibp.ru*

<sup>2</sup>School of fundamental biology and biotechnology, Siberian Federal University, Russia, Krasnoyarsk, *BartsevSI@ibp.ru*

**Abstract.** Survival in a changing environment is a task that requires identifying and remembering the most significant regularities of the environment and acting with them in mind. The ability of an organism (or an agent imitating an organism) to form and use internal representations of the external environment is called reflection in a broad sense. The article is devoted to identifying the connection between the predictability of events in the environment and the emergence of a universal skill of reflection in agents in this environment. As agents, we used heuristic model objects – simple recurrent neural networks, the primary training of which was carried out within the limit world models. These models were implemented as a set of tasks (in order of increasing predictability): responding to a random sequence of stimuli, reflexive game, responding to a set of fixed sequences, and responding to a single fixed sequence. The emergence of the universal skill of reflection after the primary training on each of these tasks was assessed by the success of the trained model objects in test tasks. The maximum Jacobian eigenvalue of the weight matrix and the type of the neural activity trajectory after the initiating single stimulus were regarded too. Based on this set of characteristics, we found out that world models with a predetermined periodicity of events (stimuli) contribute to the greatest extent to the formation of the universal reflection skill. On the contrary, in unpredictable environment conditions the emergence of internal representations is baffling. These results lead to the better understanding of reflection in a broad sense and simplify the choice of environmental conditions for further research of this phenomenon.

**Keywords:** reflection, simple recurrent neural network, reflexive game, responding to sequences of stimuli, limit world model

### References

1. Conway Christopher M. How does the brain learn environmental structure? Ten core principles for understanding the neurocognitive mechanisms of statistical learning. *Neuroscience & Biobehavioral Reviews*, 2020, vol. 112, pp. 279–299, DOI: 10.1016/j.neubiorev.2020.01.032.
2. Friston K., et al. Active inference and learning. *Neuroscience & Biobehavioral Reviews*, 2016, vol. 68, pp. 862–879, DOI: 10.1016/j.neubiorev.2016.06.022.
3. Yu L.Q., Wilson R.C., Nassar Matthew R. Adaptive learning is structure learning in time. *Neuroscience & Biobehavioral Reviews*, 2021, vol. 128, pp. 270–281, DOI: 10.1016/j.neubiorev.2021.06.024.
4. Rouhani N., Murty V.P. Episodic contributions to predictive learning. *Neuroscience & Biobehavioral Reviews*, 2025, vol. 172, p. 106122, DOI: 10.1016/j.neubiorev.2025.106122.
5. Goekoop R., de Kleijn R. Hierarchical network structure as the source of hierarchical dynamics (power-law frequency spectra) in living and non-living systems: How state-trait continua (body plans, personalities) emerge from first principles in biophysics. *Neuroscience & Biobehavioral Reviews*, 2023, vol. 154, p. 105402, DOI: 10.1016/j.neubiorev.2023.105402.
6. Erdin O., Bickhard M.H. Representing is something that we do, not a structure that we “use”: Reply to Gładziejewski. *New Ideas in Psychology*, 2018, vol. 49, pp. 27–37. DOI: 10.1016/j.newideapsych.2018.02.001.
7. Verschure P.F. M.J., Pennartz C.M.A., Pezzulo G. The why, what, where, when and how of goal-directed choice: neuronal and computational principles. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2014, vol. 369, p. 20130483, DOI: 10.1098/rstb.2013.0483.
8. Lefebvre V.A. The fundamental structures of human reflexion, *Journal of Social and Biological Structures*, 1987, vol. 10, iss.2, pp. 129–175, DOI: 10.1016/0140-1750(87)90004-2.
9. Yang An T., Lu Hui J., Chang Lei Environmental harshness and unpredictability, parenting, and offspring life history. *Evolutionary Psychological Science*, 2023, vol. 9, no.4, pp. 451–462, DOI: 10.1007/s40806-023-00375-y.
10. Fenneman J., Frankenhuis W.E. Is impulsive behavior adaptive in harsh and unpredictable environments? A formal model. *Evolution and Human Behavior*, 2020, vol. 41, no. 4, pp. 261–273, DOI: 10.1016/j.evolhumbehav.2020.02.005.
11. Pietto M.L., et al. Perceived levels of environmental unpredictability and changes in visual attention mechanisms in adults. *Behavioural Brain Research*, 2025, p. 115601, DOI: 10.1016/j.bbr.2025.115601.

12. Bartsev Sergey I., Bartseva O. D. Evristivheskiye nejrosetevye modeli v biofizike: prilozhenie k probleme strukturno-funktsional'nogo sootvetstvija [Heuristic neural network models in biophysics: application to the problem of structure–function correlation]. Krasnoyarsk, Siberian Federal University, 2010, 114 p.
13. Baciú Dan C. Neural networks through the lens of evolutionary dynamics, *BioSystems*, 2025, v.248, p. 105386. DOI: 10.1016/j.biosystems.2024.105386.
14. Von Neumann J. Teoriya samovosproizvodyszchihsya avtomatov [Theory of Self-Reproducing Automata]. Moscow, Mir, 1971, p. 382.
15. Bartsev S.I., Markova G.M., Matveeva A.I. Biofizicheskiy podkhod k modelirovaniyu refleksii: obosnovaniye, metody, rezul'taty [Biophysical approach to modeling reflection: rationale, methods, results]. *Filosofskiye problemy informatsionnykh tekhnologiy i kiberprostranstva* [Philosophical problems of information technologies and cyberspace], 2023, no. 2, pp. 120–139, DOI: 10.17726/philIT.2023.2.9.
16. Markova G.M., Bartsev S.I. Predel'no prosto ne znachit predel'no yasno: nekotoryye kontrintuitivnyye rezul'taty neyrosetevogo modelirovaniya refleksii [Extremely simple does not mean extremely clear: some counterintuitive results of neural network modeling of reflection]. *Informatsionnyye i matematicheskiye tekhnologii v nauke i upravlenii* [Information and mathematical technologies in science and management], 2025, no. 1 (37), pp. 5–15, DOI: 10.25729/ESI.2025.37.1.001.
17. Kaplan H.S., Nichols A.L.A., Zimmer M. Sensorimotor integration in *Caenorhabditis elegans*: a reappraisal towards dynamic and distributed computations. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2018, vol. 373, no.1758, p. 20170371, DOI: 10.1098/rstb.2017.0371.
18. Lamme V.A.F. Challenges for theories of consciousness: seeing or knowing, the missing ingredient and how to deal with panpsychism. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2018, vol. 373, no.1755, p. 20170344, DOI: 10.1098/rstb.2017.0344.
19. Kleene S.C. Representation of events in nerve nets and finite automata. Shannon Claude E., McCarthy John Automata Studies. Princeton University Press, 1956, pp. 3–41.
20. Markova G.M., Bartsev S.I. Does a Recurrent Neural Network Form Recognizable Representations of a Fixed Event Series? *Advances in Neural Computation, Machine Learning, and Cognitive Research VII. NI 2023. Studies in Computational Intelligence*. Eds. Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tiumentsev Y., Klimov V. Springer, Cham, 2023, vol. 1120, pp. 206-213. DOI: 10.1007/978-3-031-44865-2\_23.
21. Markova G.M., Bartsev S.I. Decoding Neural Activity of the Simplest Heterogeneous Neural Networks, In: *Advances in Neural Computation, Machine Learning, and Cognitive Research VIII. NI 2024. Studies in Computational Intelligence*. Eds. Redko V., Yudin D., Dunin-Barkowski W., Kryzhanovsky B., Tiumentsev Y. Springer, Cham, 2025, vol. 1179, pp. 362-371. DOI: 10.1007/978-3-031-80463-2\_34.
22. Bartsev S.I., Markova G.M. Does a Recurrent Neural Network Use Reflection During a Reflexive Game? *Advances in Neural Computation, Machine Learning, and Cognitive Research VI. NI 2022. Studies in Computational Intelligence*. Eds. Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tiumentsev Y. Springer, Cham, 2023, v.1064, pp. 148-157. DOI: 10.1007/978-3-031-19032-2\_15.
23. Shannon C.E. A mind-reading machine. Bell Laboratories memorandum, 1953.
24. Johnston J.W., Fusi S. Abstract representations emerge naturally in neural networks trained to perform multiple tasks. *Nature Communications*, 2023, vol. 14, no.1, p. 1040, DOI: 10.1038/s41467-023-36583-0.
25. Stroud Jake P, Duncan John, Lengyel Mate The computational foundations of dynamic coding in working memory. *Trends in Cognitive Sciences*, 2024, vol. 28, iss.7, pp. 614-627, DOI: 10.1016/j.tics.2024.02.011.
26. Anokhin P.K. Izbrannyye trudy: filosofskiye aspekty teorii funktsional'nykh sistem [Selected Works: Philosophical Aspects of the Theory of Functional Systems]. Moscow, Nauka [Science] Publ., 1978, 400 p.
27. Kanaev A.I., Dryaeva E.D. The Evolutionary Pathway to Consciousness and Reason: the Cognitome from a Philosophical Perspective. *Neuroscience and Behavioral Physiology*, 2023, vol. 53, no.7, pp. 1146–1157, DOI: 10.1007/s11055-023-01511-8.

**Markova Galiya Muratovna.** Junior researcher at the Institute of Biophysics SB RAS, assistant at the Department of Biophysics at the School of Fundamental Biology and Biotechnology SibFU. Main areas of research: neural network modeling of cognitive functions, neuroinformatics. AuthorID: 1075515, SPIN: 1664-7436, ORCID: 0000-0003-1726-8102, GMarkova@ibp.ru, 660036, Krasnoyarsk, Akademgorodok str., 50, building 50.

**Bartsev Sergey Igorevich.** Doctor of Physical and Mathematical Sciences, Chief Researcher at the Institute of Biophysics SB RAS, Head of the Laboratory of Theoretical Biophysics at the Institute of Biophysics SB RAS, Professor at the Department of Biophysics at the School of Fundamental Biology and Biotechnology SibFU. Main research areas: neural network modeling of cognitive functions, neuroinformatics, small-scale biosphere models, reducing the complexity of biological systems models, designing biological life support systems for space applications. AuthorID: 66068, SPIN: 1884-5876, ORCID: 0000-0003-0140-4894, BartsevSI@ibp.ru, 660036, Krasnoyarsk, Akademgorodok str., 50, building 50.

Статья поступила в редакцию 12.11.2025; одобрена после рецензирования 28.04.2026; принята к публикации 11.05.2026.

The article was submitted 11/12/2025; approved after reviewing 04/28/2026; accepted for publication 05/11/2026.

## Методы, технологии и приложения искусственного интеллекта

УДК 519.6

DOI:10.25729/ESI.2026.42.2.003

### Модифицированный подход к управлению параметрами генетического алгоритма на основе глубокого обучения с подкреплением

Привалов Константин Сергеевич

Финансовый университет при Правительстве РФ,  
Россия, Москва, *qqstik@gmail.com*

**Аннотация.** Актуальность исследования обусловлена тем, что эффективность классических генетических алгоритмов (ГА) при решении задач глобальной оптимизации существенно зависит от выбора вероятностей кроссовера и мутации, а фиксированные значения параметров нередко приводят к преждевременной сходимости и стабилизации популяции в окрестности локальных экстремумов. Цель работы – разработать и экспериментально оценить подходы к адаптивному управлению параметрами ГА на основе искусственных нейронных сетей и обучения с подкреплением. В рамках единой математической постановки определены признаки состояния популяции, множество действий (дискретные изменения вероятностей мутации и кроссовера  $p_m$  и  $p_c$ ) и функция вознаграждения, отражающая улучшение качества решения между поколениями с учетом штрафа за чрезмерно высокую мутацию. Рассмотрены четыре варианта алгоритма: классический ГА с фиксированными параметрами, гибридный ГА с нейросетевым регулятором (GA+NN), ГА с табличным Q-learning (GA+RL) и предлагаемый метод управления параметрами на основе глубокого Q-обучения, использующий нейронную сеть для аппроксимации Q-функции (GA+DQN). Научная новизна работы состоит в интеграции DQN-агента в контур параметрического управления ГА в рамках формализованной модели «состояние–действие–награда» и в сопоставлении его эффективности с нейросетевым регулятором и табличным Q-обучением на задачах непрерывной оптимизации. Численные эксперименты выполнены на тестовых функциях Растригина и Шаффера при 20 независимых прогонах для каждой конфигурации. В качестве итоговых метрик использовались лучшее значение целевой функции в последнем поколении  $f_{min}(T_{max})$  и наилучшее значение, достигнутое за весь прогон. Показано, что GA+RL обеспечивает наибольшее улучшение качества решений. Метод GA+DQN демонстрирует умеренное улучшение относительно базового ГА, подтверждая работоспособность глубокой аппроксимации Q-функции при управлении параметрами. Нейросетевой регулятор в рассмотренной схеме обучения показывает высокую чувствительность к настройкам и в данных экспериментах уступает RL-подходам. Результаты сравнения представлены в виде графиков сходимости, анализа показателей разнообразия популяции и сводной таблицы.

**Ключевые слова:** генетический алгоритм, адаптивное управление параметрами, обучение с подкреплением, гибридные эволюционные алгоритмы

**Цитирование:** Привалов К.С. Модифицированный подход к управлению параметрами генетического алгоритма на основе глубокого обучения с подкреплением / К.С. Привалов // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 29-41. – DOI:10.25729/ESI.2026.42.2.003.

**Введение.** В различных областях науки и техники задачи оптимизации играют ключевую роль, поскольку позволяют находить наилучшие решения при ограниченных ресурсах. Одним из наиболее распространённых подходов к поиску оптимальных решений являются эволюционные алгоритмы, в частности генетические алгоритмы (ГА), зарекомендовавшие себя способностью решать сложные многопараметрические задачи с множеством локальных экстремумов [1-4]. Однако классический ГА нередко сталкивается с проблемой преждевременной сходимости, когда популяция быстро теряет генетическое разнообразие и концентрируется около локального экстремума. Эта проблема особенно проявляется при росте размерности задачи или на так называемых «обманых» тестовых функциях с большим числом локальных минимумов, таких, как функция Растригина [5]. В результате эффективность классического алгоритма снижается, и он нередко ограничивается поиском лишь субоптимальных (локальных) решений.

Для повышения эффективности эволюционного поиска и предотвращения преждевременной сходимости предложены различные методы адаптивного управления параметрами ГА. Наиболее изучены подходы автоматической настройки вероятностей мутации и кроссовера, а также введение специальных операторов для поддержания разнообразия популяции [6]. В последнее время, включая предыдущие работы автора [7, 8] и ряд других исследований [9-11], перспективным направлением становится использование искусственных нейронных сетей (ИНС) в структуре эволюционного алгоритма. Нейросетевой модуль способен в реальном времени корректировать параметры эволюционного процесса (например, вероятности мутации и кроссовера) на основе текущей статистики популяции, что повышает устойчивость алгоритма к локальным экстремумам и ускоряет его сходимость. Однако нейросетевые подходы требуют тщательного выбора архитектуры сети, предварительного обучения на специализированных данных и чувствительны к подбору гиперпараметров, что ограничивает их универсальность в разных задачах.

Одновременно с этим, успехи методов обучения с подкреплением (Reinforcement Learning, RL) в задачах управления и оптимизации открывают новые возможности для адаптивного регулирования эволюционного поиска [9, 10]. В отличие от статических или даже нейросетевых схем, RL-агент способен не только реагировать на текущее состояние поиска, но и обучаться долгосрочной стратегии взаимодействия с популяцией на основе получаемого вознаграждения за улучшение решения. Такой подход позволяет агенту накапливать «опыт» процесса оптимизации и более гибко адаптировать параметры алгоритма при изменении обстановки в пространстве решений. Благодаря обучению без учителя RL-агент формирует внутреннюю модель динамики поиска, что даёт потенциал для более эффективного выхода из локальных экстремумов и ускоренного достижения глобального экстремума.

В предыдущей работе автора [8] была предложена гибридная схема, в которой табличный алгоритм Q-обучения использовался для адаптивного выбора вероятностей мутации и кроссовера в зависимости от состояния популяции. Эксперименты показали, что такой подход обеспечивает более быстрое и устойчивое приближение к глобальному экстремуму по сравнению с классическим ГА и схемой с нейросетевым регулятором. Вместе с тем табличный Q-алгоритм требует дискретизации пространства состояний и действий, что ограничивает его применимость при большом числе признаков состояния и усложняет расширение модели.

Отметим, что в отечественной научной литературе также активно развиваются подходы к управлению и самонастройке генетических алгоритмов. В частности, предлагаются методы представления состояния популяции и обучения нейросетевых моделей для управления работой ГА в процессе оптимизации [12], а также схемы управления ГА с использованием формализованных моделей (в т.ч. на основе аппарата сетей Петри) [13]. Рассматриваются подходы, анализирующие влияние операторов ГА (кроссовера и мутации) на динамику сходимости и предлагающие правила их применения для повышения устойчивости эволюционного поиска [14]. Отдельный интерес представляют самоконфигурируемые ГА с адаптацией по истории успешности параметров, ориентированные на повышение надежности и воспроизводимости результатов [15], а также адаптивные ГА для прикладных задач, где автоматическая настройка параметров сочетается с оптимизированными схемами рекомбинации [16].

**1. Цели и задачи исследования.** Целью настоящего исследования является разработка и экспериментальная оценка моделей адаптивного управления параметрами генетического алгоритма на основе методов обучения с подкреплением, а также сравнение их эффективности с классическим генетическим алгоритмом и гибридным подходом с нейросетевым регулятором в задачах многомерной оптимизации. Объектом исследования выступают

эволюционные методы глобальной оптимизации, основанные на генетическом алгоритме. Предметом исследования являются математические модели и алгоритмы адаптивного управления параметрами генетического алгоритма (прежде всего вероятностями кроссовера и мутации) с использованием искусственных нейронных сетей и методов обучения с подкреплением, а также их программная реализация и численная оценка эффективности.

Для достижения поставленной цели в работе решаются следующие задачи:

1. Построить единую формальную модель генетического алгоритма с параметрическим управлением, в которой вероятности кроссовера и мутации рассматриваются как управляемые переменные, зависящие от состояния популяции и хода эволюции.
2. Систематизировать и уточнить ранее предложенные подходы к адаптивному управлению параметрами ГА:
  - Схему с нейросетевым регулятором, использующим статистику популяции в качестве входных признаков.
  - Схему с табличным Q-обучением, в которой выбор управляющих воздействий трактуется как задача обучения с подкреплением.
3. Разработать усовершенствованный вариант гибридного алгоритма на основе глубокого обучения с подкреплением (Deep Q-Network), в котором нейронная сеть аппроксимирует функцию ценности и позволяет отказаться от жёсткой дискретизации пространства состояний популяции.
4. Реализовать программный прототип исследуемых алгоритмов (классический ГА, ГА с нейросетевым регулятором, ГА с Q-learning и ГА с DQN) в виде единого программного комплекса, обеспечивающего воспроизводимое проведение вычислительных экспериментов и сбор статистики.
5. Провести серию вычислительных экспериментов на наборе тестовых задач оптимизации (функции Растригина, Шаффера), сравнив рассматриваемые алгоритмы по критериям:
  - Скорость сходимости.
  - Качество найденных решений.
  - Устойчивость к преждевременной сходимости.
  - Уровень генетического разнообразия популяции.
6. Выполнить анализ полученных результатов, выявить характерные стратегии адаптивного управления параметрами (в том числе на основе тепловых карт и динамики параметров), сформулировать выводы о преимуществах и ограничениях каждого подхода и предложить практические рекомендации по применению разработанных алгоритмов в задачах численной оптимизации.

Научная новизна состоит в разработке и экспериментальной проверке схемы адаптивного управления параметрами генетического алгоритма на основе глубокого обучения с подкреплением. В предлагаемом подходе используется нейронная сеть для аппроксимации функции ценности (Q-функции) и выбора управляющих воздействий на параметры  $p_c^{(t)}, p_m^{(t)}$  в зависимости от текущего состояния популяции. В отличие от табличного Q-learning, предложенная модификация не требует жёсткой дискретизации пространства состояний и может масштабироваться на более информативные признаки популяции.

**2. Методы и используемые модели.** Во всех рассматриваемых вариантах используется одна и та же эволюционная основа – генетический алгоритм с действительным кодированием, описанный в [7, 8]. Поэтому в настоящей работе приведём лишь обобщённую схему, а подробное описание операторов селекции, кроссовера и мутации будем считать известными.

**2.1 Общая структура гибридного алгоритма.** Пусть на шаге эволюции  $t$  задана популяция:

$$P^{(t)} = \{x_1^{(t)}, \dots, x_N^{(t)}\}, x_k^{(t)} \in \Omega \in \mathbb{R}^n,$$

а целевая функция  $f(x)$  определяется, например, как функция Растригина или Шаффера. Для каждой особи вычисляется значение целевой функции:

$$F_k^{(t)} = f(x_k^{(t)}),$$

и далее выполняются стандартные шаги ГА: селекция, кроссовер, мутация, формирование нового поколения и проверка критерия остановки. Ключевую роль в работе алгоритма играют вероятности кроссовера и мутации:

- $p_c^{(t)}$  – вероятность применения оператора кроссовера (скрещивания) к паре родителей на шаге  $t$ .
- $p_m^{(t)}$  – вероятность мутации отдельного гена (компоненты вектора решения) на шаге  $t$ .

В классическом ГА эти величины постоянны и задаются до начала работы алгоритма, а во всех гибридных схемах, рассматриваемых в настоящей работе, предполагается наличие модуля управления параметрами  $U$ , который по состоянию популяции на шаге  $t$  формирует значения  $p_c^{(t)}, p_m^{(t)}$ :

$$(p_c^{(t)}, p_m^{(t)}) = U(s_t),$$

где  $s_t$  – вектор признаков, описывающих текущее состояние популяции (статистики по значениям функции, разнообразие и др.). Конкретная форма оператора  $U$  различается для разных подходов:

1. Классический ГА:  $U$  тождественно возвращает фиксированные значения  $p_c, p_m$ .
2. ГА + ИНС:  $U$  реализуется нейронной сетью, обучаемой по мере работы алгоритма.
3. ГА + табличный Q-learning:  $U$  задаётся стратегией RL-агента, использующего Q-таблицу.
4. ГА + DQN:  $U$  задаётся нейросетью, аппроксимирующей Q-функцию, и обучаемой по алгоритму глубокого Q-обучения.

Таким образом, эволюционная часть алгоритма во всех случаях одинакова; различия касаются только способа формирования управляющих параметров  $p_c^{(t)}, p_m^{(t)}$ . Это удобно как для теоретического сравнения, так и для программной реализации, поскольку позволяет использовать один и тот же код ГА и переключать только модуль управления.

Детально описывать базовый ГА и нейросетевой регулятор не будем. Основное внимание уделяется новой модификации модуля  $U$  на основе Q-обучения [11].

**2.2 Модель управления параметрами ГА на основе глубокого Q-обучения.** В предлагаемой модификации гибридного алгоритма модуль управления параметрами генетического алгоритма реализуется в виде агента обучения с подкреплением, использующего нейросеть для аппроксимации функции ценности (DQN) [9–11]. Эволюционный процесс ГА рассматривается как среда, с которой взаимодействует RL-агент.

На шаге эволюции  $t$  состояние среды описывается вектором статистик текущей популяции:

$$s_t = (\bar{f}^{(t)}, f_{min}^{(t)}, f_{max}^{(t)}, \sigma_f^{(t)}, D^{(t)})^T,$$

где  $\bar{f}^{(t)}$  – среднее значение целевой функции по популяции,  $f_{min}^{(t)}$  и  $f_{max}^{(t)}$  – лучшее и худшее значения,  $\sigma_f^{(t)}$  – стандартное отклонение, а  $D^{(t)}$  – мера разнообразия популяции (например, среднее попарное расстояние между особями).

Действием агента на шаге  $t$  является выбор приращений к вероятностям кроссовера и мутации для следующего поколения. Рассматривается конечное множество действий:

$$A = \{(\Delta p_c, \Delta p_m)\},$$

где  $\Delta p_c$  и  $\Delta p_m$  принимают значения из ограниченного набора. Новые значения параметров вычисляются по формулам:

$$\begin{aligned} p_c^{(t+1)} &= \text{clip}(p_c^{(t)} + \Delta p_c, p_c^{\min}, p_c^{\max}), \\ p_m^{(t+1)} &= \text{clip}(p_m^{(t)} + \Delta p_m, p_m^{\min}, p_m^{\max}), \end{aligned}$$

где функция *clip* ограничивает значение на заданном отрезке. Тем самым, как и в табличном Q-алгоритме [8], агент дискретно изменяет параметры ГА, но оценка качества действий выполняется нейросетью.

После формирования нового поколения  $P^{(t+1)}$  вычисляется награда, отражающая изменение качества популяции:

$$r_{t+1} = \bar{f}^{(t)} - \bar{f}^{(t+1)}.$$

Положительное значение  $r_{t+1}$  соответствует уменьшению среднего значения целевой функции (улучшение), отрицательное – ухудшению или стагнации.

Для аппроксимации функции ценности  $Q(s, a)$  используется полносвязная нейронная сеть с параметрами  $\theta$ . Сеть принимает на вход вектор состояния  $s_t$  и возвращает оценки значений  $Q(s_t, a_j)$  для всех действий  $a_j \in A$ :

$$Q(s_t, a_j; \theta), \quad j = 1, \dots, |A|.$$

Выбор действия выполняется по  $\varepsilon$  – жадной стратегии. с вероятностью  $\varepsilon_t$  выбирается случайное действие (исследование), с вероятностью  $1 - \varepsilon_t$  выбирается действие с максимальной оценкой  $Q(s_t, a; \theta)$ .

В процессе работы алгоритма в буфер опыта накапливаются переходы вида:

$$(s_t, a_t, r_{t+1}, s_{t+1}).$$

Через регулярные интервалы из буфера выбирается случайный мини-батч переходов, и для каждого перехода вычисляется целевое значение:

$$y_t = r_{t+1} + \gamma \max_{a' \in A} Q(s_{t+1}, a'; \theta^-),$$

где  $\gamma$  – коэффициент дисконтирования, а  $\theta^-$  – параметры целевой сети, обновляемой реже, чем основная сеть. Параметры  $\theta$  основной сети находятся путём минимизации средней квадратичной ошибки:

$$\mathcal{L}(\theta) = \frac{1}{B} \sum_{tebatch} (y_t - Q(s_t, a_t; \theta))^2,$$

где  $B$  – размер мини-батча. Обновление параметров  $\theta$  выполняется методом стохастического градиентного спуска.

Таким образом, на каждом шаге  $t$  гибридный алгоритм «ГА + DQN» работает по следующей схеме:

1. По текущей популяции  $P^{(t)}$  вычисляется состояние  $s_t$ .
2. DQN-агент выбирает действие  $a_t$  и, следовательно, значения  $p_c^{(t)}$  и  $p_m^{(t)}$ .
3. С выбранными параметрами выполняются операторы селекции, кроссовера и мутации, формируются особи нового поколения  $P^{(t+1)}$ .
4. Вычисляется награда  $r_{t+1}$  и новое состояние  $s_{t+1}$ .
5. Переход  $(s_t, a_t, r_{t+1}, s_{t+1})$  добавляется в буфер опыта, выполняется шаг обучения сети.

В итоге, DQN-агент по ходу эволюции ГА самообучается стратегии управления параметрами, стремясь максимизировать суммарное улучшение качества популяции. В отличие от табличного Q-обучения, нейросетевая аппроксимация Q-функции позволяет работать с непрерывным пространством признаков состояния и обобщать накопленный опыт, что особенно важно при использовании более богатого набора статистик популяции и при росте размерности задач [9–11].

**3. Постановка эксперимента.** Для экспериментальной оценки предложенного алгоритма и базовых схем были проведены численные эксперименты на наборе стандартных тестовых функций глобальной оптимизации. В настоящей работе подробно рассматриваются две функции:

1. Функция Растргина размерности  $n = 10$  с областью допустимых значений  $x_i \in [-5.12, 5.12]$ .
2. Функция Шаффера (модификация N.2) в двумерном пространстве с областью  $x, y \in [-100, 100]$ .

В расчётном блоке реализованы четыре варианта алгоритма:

1. GA – классический генетический алгоритм с фиксированными параметрами  $p_c, p_m$ .
2. GA+NN – гибридный ГА с нейросетевым регулятором параметров, обучаемый по разности средних значений целевой функции между поколениями.
3. GA+RL – гибридный ГА с табличным Q-learning, управляющим дискретными изменениями  $p_c, p_m$ .
4. GA+DQN – предлагаемый в работе гибридный алгоритм, в котором управление параметрами выполняет агент глубокого Q-обучения (DQN) с нейросетевой аппроксимацией Q-функции.

Во всех вариантах использовалась единая эволюционная схема, реализованная с помощью библиотеки DEAP:

- Тип кодирования: действительный вектор длины  $n$ .
- Способ инициализации: равномерное распределение на отрезке  $[x_i^{min}, x_i^{max}]$ .
- Размер популяции:  $N = 50$  для обеих задач.
- Оператор селекции: турнирный отбор с размером турнира 3.
- Оператор кроссовера: двухточечный кроссовер.
- Оператор мутации: гауссовская мутация с нулевым средним и фиксированным стандартным отклонением, с последующей проекцией решения в допустимую область.
- Элитизм: сохранение лучшей особи из поколения в поколение.

Для классического ГА начальные значения параметров выбирались, как:

$$p_c = 0.7, \quad p_m = 0.2,$$

и далее оставались неизменными. Во всех адаптивных вариантах алгоритма эти значения использовались в качестве стартовых, после чего динамически корректировались соответствующим управляющим модулем (нейросетью, Q-агентом или DQN-агентом). Число поколений в одном прогоне составляло  $T_{max} = 50$ . Для оценки устойчивости алгоритмов каждая конфигурация (комбинация функции и варианта ГА) запускалась на 20 независимых прогонах при фиксированном лимите поколений. Во всех сериях экспериментов использовались одинаковые генераторы случайных чисел (NumPy/DEAP) и фиксированное начальное состояние генератора для воспроизводимости эксперимента.

В гибридном алгоритме GA+NN управляющий модуль реализовывался полносвязной нейронной сетью с одним скрытым слоем из 16 нейронов и функцией активации ReLU. На вход сети подавался вектор статистик популяции  $s_t$ . Выход сети интерпретировался, как желательные значения вероятностей мутации и кроссовера, ограниченные в допустимом диапазоне. Обучение проводилось методом стохастического градиентного спуска (оптимизатор Adam, скорость обучения  $10^{-3}$ ) по квадратичной функции потерь между фактическим выходом сети и «целевыми» значениями параметров, вычисляемыми из улучшения среднего значения функции между поколениями.

В предлагаемом алгоритме GA+DQN Q-функция аппроксимировалась нейронной сетью с двумя скрытыми слоями по 32 нейрона и активацией ReLU. На вход сети подавался


расширенный вектор состояния, включающий статистики популяции и текущие значения  $p_c$  и  $p_m$ . На выходе сеть возвращала оценки  $Q(s_t, a_j)$  для всех действий  $a_j$  из того же дискретного набора, что и в табличном Q-learning. Обучение сети осуществлялось по методу Deep Q-Network с буфером повторов объёмом  $10^4$  переходов, размером мини-батча 32, коэффициентом дисконтирования  $\gamma = 0.99$ , скоростью обучения  $10^{-3}$  и периодическим обновлением целевой сети (каждые 50 шагов обучения). Выбор действий осуществлялся по  $\epsilon$  – жадной стратегии.

Для каждого прогона фиксировались следующие величины по поколениям:

- Лучшее значение целевой функции в популяции  $f_{min}^{(t)}$ .
- Среднее значение  $\bar{f}^{(t)}$ .
- Мера разнообразия популяции  $D^{(t)}$ .
- Фактические значения параметров мутации и кроссовера  $p_m^{(t)}, p_c^{(t)}$ .

На основе этих данных строились усреднённые кривые сходимости по лучшему значению функции, графики изменения вероятности мутации, а также сводные таблицы с числовыми характеристиками (среднее и стандартное отклонение финального лучшего значения по 20 прогонам).


**3.1 Сходимость и качество решения.** На рис. 1 и рис. 2 представлены усреднённые по 20 независимым прогонам кривые сходимости по лучшему значению функции в поколении для функций Растригина и Шаффера соответственно. Для каждой задачи сравниваются четыре варианта алгоритма: классический ГА, гибрид с нейросетевым регулятором (GA+NN), гибрид с табличным Q-learning (GA+RL) и предлагаемый алгоритм GA+DQN.



**Рис. 1.** Сходимость по лучшему значению и динамика вероятности мутации для функции Растригина

Из рис. 1 видно, что классический ГА демонстрирует типичное поведение: в первые 10–15 поколений наблюдается существенное снижение  $f_{min}^{(t)}$ , после чего сходимость замедляется, и к 50-му поколению среднее лучшее значение составляет порядка 13. Гибрид с нейросетевым регулятором в данной постановке задач уступает базовому алгоритму: его кривая сходимости на всём интервале поколений проходит выше, а итоговое среднее значение  $f_{min}^{(50)}$  находится около 24. Наилучший результат показывает гибрид GA+RL: за счёт более агрессивной адаптации параметров на ранних этапах поиска он быстрее снижает  $f_{min}^{(t)}$  и к 50-му поколению достигает в среднем значения около 8.7, что заметно лучше классического ГА. Предлагаемый алгоритм GA+DQN на функции Растригина демонстрирует поведение, близкое к базовому методу: его кривая чуть смещена вниз, а среднее финальное значение порядка 12.7 лишь

немного превосходит результат классического ГА, но существенно лучше, чем у варианта GA+NN.



**Рис. 2.** Сходимость по лучшему значению и динамика вероятности мутации для функции Шаффера

Для двумерной функции Шаффера (рис. 2) классический ГА в среднем выходит на значения  $f_{min}^{(50)}$  порядка 0.18, причём сходимость после первых 10 поколений становится более полой. Нейросетевой гибридом GA+NN также не даёт выигрыша и даже несколько ухудшает результаты: его кривая сходимости на всём протяжении остаётся выше, а финальное среднее значение достигает около 0.22. Наиболее быстрое и глубокое снижение  $f_{min}^{(t)}$  обеспечивает метод GA+RL: уже после 10–15 поколений он достигает уровня порядка 0.1, а к 50-му поколению среднее лучшее значение становится около 0.08, что примерно в два раза лучше результата классического ГА. Предлагаемый алгоритм GA+DQN на этой задаче занимает промежуточное положение: кривая сходимости проходит ниже классического ГА и выше GA+RL, финальное среднее значение  $f_{min}^{(50)}$  составляет около 0.15.

В целом, представленные графики показывают, что применение методов обучения с подкреплением (Q-learning и DQN) позволяет улучшить качество решений и ускорить сходимость генетического алгоритма на рассматриваемых тестовых функциях. При этом простая схема нейросетевого регулирования параметров без явно заданной функции награды оказывается менее эффективной и в ряде случаев уступает базовому варианту ГА.

**3.2 Сводные количественные показатели.** Для количественной оценки качества работы алгоритмов были использованы две метрики:

1. Среднее значение лучшей найденной особи в последнем поколении  $f_{min}^{(Tmax)}$  по 20 прогонам (со стандартным отклонением).
2. Среднее по прогонам наименьшее значение целевой функции, достигнутое за всё время работы алгоритма (минимум по поколениям), также со стандартным отклонением.

Сводные результаты для функций Растригина (10 измерений) и Шаффера (2 измерения) приведены в таблице 1.

На функции Растригина гибридом GA+RL демонстрирует наилучшие показатели: среднее финальное значение  $f_{min}^{(Tmax)}$  составляет 8.67 при стандартном отклонении 3.12, тогда как классический ГА достигает  $13.04 \pm 5.23$ . Предлагаемый алгоритм GA+DQN по финальному значению ( $12.67 \pm 3.99$ ) сопоставим с базовым методом и немного улучшает его результат, тогда как вариант с нейросетевым регулятором (GA+NN) заметно уступает остальным ( $24.02 \pm 8.19$ ). Аналогичная картина наблюдается и по метрике «лучшее значение за прогон»:  $8.49 \pm 3.02$  для GA+RL против  $13.00 \pm 5.26$  для классического ГА и  $12.41 \pm 3.93$  для GA+DQN.

**Таблица 1.** Результаты экспериментов на функциях Растригина и Шаффера

Функция	Алгоритм	$f_{min}^{(Tmax)}$ (среднее $\pm$ $\sigma$ )	$f_{min}^{best}$ (среднее $\pm$ $\sigma$ )
Растринг	GA	13.043 $\pm$ 5.230	12.996 $\pm$ 5.255
Растринг	GA+NN	24.016 $\pm$ 8.189	21.998 $\pm$ 8.421
Растринг	GA+RL	8.670 $\pm$ 3.123	8.489 $\pm$ 3.019
Растринг	GA+DQN	12.665 $\pm$ 3.995	12.413 $\pm$ 3.925
Шаффер	GA	0.184 $\pm$ 0.137	0.157 $\pm$ 0.120
Шаффер	GA+NN	0.219 $\pm$ 0.128	0.192 $\pm$ 0.125
Шаффер	GA+RL	0.083 $\pm$ 0.084	0.078 $\pm$ 0.076
Шаффер	GA+DQN	0.152 $\pm$ 0.125	0.141 $\pm$ 0.118

На функции Шаффера лучшим по обоим критериям также оказывается метод GA+RL: среднее финальное значение составляет  $0.083 \pm 0.084$ , тогда как классический ГА даёт  $0.184 \pm 0.137$ , а GA+DQN —  $0.152 \pm 0.125$ . Вариант GA+NN снова показывает наихудший результат ( $0.219 \pm 0.128$ ). По метрике минимального значения за прогон GA+RL достигает в среднем  $0.078 \pm 0.076$ , что существенно лучше как классического ГА ( $0.157 \pm 0.120$ ), так и алгоритма GA+DQN ( $0.141 \pm 0.118$ ).

Таким образом, сводные численные показатели подтверждают выводы, сделанные по графикам сходимости: табличный Q-learning обеспечивает наибольший выигрыш по качеству найденных решений, особенно на многомодальных задачах, тогда как DQN даёт устойчивые, сопоставимые с классическим ГА результаты и выступает как более универсальный, но менее «острый» регулятор. Нейросетевой регулятор в рассмотренной схеме обучения показал чувствительность к настройкам и в текущей конфигурации уступает как базовому методу, так и алгоритмам с обучением с подкреплением.

**3.2 Выводы по результатам экспериментов.** Проведённые вычислительные эксперименты позволяют сделать следующие выводы:

1. Использование обучения с подкреплением для управления параметрами ГА приводит к значительному выигрышу по качеству решений. На обеих тестовых функциях гибридный GA+RL обеспечивает существенное снижение финального значения  $f_{min}^{(Tmax)}$  по сравнению с классическим ГА. На функции Растригина улучшение составляет порядка 30–35 %, на функции Шаффера – примерно двукратное уменьшение средних значений.
2. Глубокий вариант Q-обучения (GA+DQN) демонстрирует устойчивое поведение и умеренный выигрыш. На функции Растригина DQN незначительно улучшает классический ГА, а на функции Шаффера даёт результат лучше базового алгоритма, но хуже табличного Q-learning. Это показывает, что при ограниченном числе поколений и сравнительно небольшом объёме данных более простая табличная схема может оказаться эффективнее сложной нейросетевой аппроксимации.
3. Нейросетевой регулятор параметров в простой схеме обучения не гарантирует улучшения. В рассмотренной конфигурации метод GA+NN на обеих функциях уступает даже классическому ГА. Это подчёркивает, что применение ИНС для адаптивной настройки параметров требует тщательного выбора архитектуры, нормировки признаков и стратегии обучения, в противном случае эффект от такого усложнения алгоритма может быть отрицательным.
4. На правых графиках рис. 1 и 2 видно, что GA+RL активно изменяет  $p_m$ , повышая её на начальных этапах поиска и постепенно снижая по мере приближения к минимуму, тогда как DQN предпочитает более плавные изменения, а классический ГА работает в фиксированном режиме. Нейросетевая схема показывает менее интерпретируемую и более вариативную траекторию  $p_m$ , что коррелирует с её нестабильной эффективностью.

**Заключение.** В работе выполнено сравнение четырех схем управления параметрами генетического алгоритма: классического ГА с фиксированными  $p_m$  и  $p_c$ , ГА с нейросетевым регулятором (GA+NN), ГА с табличным Q-learning (GA+RL) и предложенного подхода GA+DQN, использующего нейронную аппроксимацию Q-функции. Сформулирована единая математическая модель в терминах «состояние–действие–награда» и реализован программный комплекс для воспроизводимых численных экспериментов. По результатам 20 независимых прогонов показано, что применение обучения с подкреплением повышает качество решений и устойчивость поиска: для функции Растригина среднее значение  $f_{min}(T_{max})$  уменьшилось с  $13.04 \pm 5.23$  (ГА) до  $8.67 \pm 3.12$  (GA+RL), а для функции Шаффера — с  $0.184 \pm 0.137$  до  $0.083 \pm 0.084$ , что соответствует улучшению порядка 33% и 55% соответственно. Подход GA+DQN демонстрирует сопоставимые с базовым ГА результаты ( $12.67 \pm 3.99$  и  $0.152 \pm 0.125$ ) и подтверждает применимость глубокого обучения с подкреплением к задаче параметрического управления эволюционным поиском. Нейросетевой регулятор в текущей схеме обучения оказался чувствителен к настройкам и уступил RL-методам. Полученные выводы подтверждают достижение цели исследования и могут быть использованы при разработке прикладных систем глобальной оптимизации и адаптивной настройки метаэвристик.

Практическая значимость результатов заключается в возможности применения предложенных регуляторов параметров  $p_m$  и  $p_c$  при разработке прикладных систем глобальной оптимизации и модулей автоматической настройки метаэвристик, в том числе для задач с риском преждевременной сходимости. Материалы статьи могут быть интересны специалистам по численным методам оптимизации, эволюционным вычислениям, а также исследователям, использующим нейросетевые и RL-подходы для управления процессом поиска.

#### Список источников

1. Goldberg D.E. Genetic Algorithms in Search, Optimization, and Machine Learning. Reading, MA, Addison-Wesley, 1989, 432 p.
2. Holland J.H. Adaptation in Natural and Artificial Systems. Ann Arbor, MI, University of Michigan Press, 1975, 183 p.
3. Fogel D.B. Evolutionary Computation: Toward a New Philosophy of Machine Intelligence. 3rd ed. Hoboken, NJ, IEEE Press, 2006, 296 p.
4. Wolpert D.H., Macready W.G. No Free Lunch Theorems for Optimization. IEEE Transactions on Evolutionary Computation, 1997, vol. 1, no. 1, pp. 67–82.
5. Растригин Л.А. О сходимости случайного поиска при экстремальном управлении многопараметрическими системами / Л.А. Растригин // Автоматика и телемеханика, 1963. – Т. 24. – С. 1337–1342.
6. Zhang J., Liao S., Lee S. The Use of Neural Networks for Adaptive Optimization Problems in Large Dimensions. Applied Soft Computing, 2020, vol. 90, art. 106187.
7. Привалов К.С. Гибридные методы оптимизации: адаптивное управление эволюционным процессом с использованием искусственных нейронных сетей / К.С. Привалов // Инженерный вестник Дона, 2025. – № 3. – URL: <http://www.ivdon.ru/ru/magazine/archive/n3y2025/9910> (дата обращения: 06.12.2025).
8. Привалов К.С. Обучение с подкреплением в адаптивном управлении параметрами генетического алгоритма / К.С. Привалов // Инженерный вестник Дона, 2025. – № 8. – URL: <http://www.ivdon.ru/ru/magazine/archive/n8y2025/10315> (дата обращения: 06.12.2025).
9. Sutton R.S., Barto A.G. Reinforcement Learning: An Introduction. 2nd ed. Cambridge, MA, The MIT Press, 2018, 552 p.
10. Mnih V., Kavukcuoglu K., Silver D., et al. Human-level Control through Deep Reinforcement Learning. Nature, 2015, vol. 518, no. 7540, pp. 529–533.
11. Sharma M., Komninos A., López-Ibáñez M., et al. Deep Reinforcement Learning Based Parameter Control in Differential Evolution. GECCO '19: Proceedings of the Genetic and Evolutionary Computation Conference. Prague, ACM, 2019, pp. 709–717.
12. Петросов Д.А. Представление данных о состоянии популяции и обучение искусственной нейронной сети в задаче управления работой генетическим алгоритмом / Д.А. Петросов, Н.А. Андриянов, А.Н. Алюнов,

- Е.В. Нежданов // Экономика. Информатика, 2023. – Т. 50. – № 4. – С. 924–935. – DOI: 10.52575/2712-746X-2023-50-4-924-935. – URL: <https://econom-inform-journal.ru/index.php/journal/article/view/330> (дата обращения: 21.01.2026).
13. Петросов Д.А. Модель искусственной нейронной сети для решения задачи управления генетическим алгоритмом с применением математического аппарата теории сетей Петри / Д.А. Петросов, А.Н. Зеленина // Моделирование, оптимизация и информационные технологии, 2020. – Т. 8. – № 4. – DOI: 10.26102/2310-6018/2020.31.4.031. – URL: <https://moitvvt.ru/ru/journal/pdf?id=877> (дата обращения: 21.01.2026).
14. Петросов Д.А. Правила применения разрушающей способности операторов генетического алгоритма в задаче структурно-параметрического синтеза имитационных моделей бизнес-процессов / Д.А. Петросов, Н.Ю. Сурова, А.В. Поляков // Моделирование, оптимизация и информационные технологии, 2023. – Т. 11. – № 4. – DOI: 10.26102/2310-6018/2023.43.4.013. – URL: <https://moitvvt.ru/ru/journal/pdf?id=1463> (дата обращения: 21.01.2026).
15. Шерстнев П.А. SelfCSHAGA: самоконфигурируемый генетический алгоритм оптимизации с адаптацией на основе истории успеха / П.А. Шерстнев, Е.С. Семенкин // Вестник МГТУ им. Н.Э. Баумана. Серия «Приборостроение», 2025. – № 2 (151). – С. 122–139. – EDN: TSKBOX. – URL: <https://vestnikprib.bmstu.ru/catalog/icec/sysan/1363.html> (дата обращения: 21.01.2026).
16. Сахно М.Ю. Адаптивный генетический алгоритм с оптимальной рекомбинацией для задачи составления расписаний с учетом расхода энергии / М.Ю. Сахно // Сибирский журнал вычислительной математики. – 2025. – Т. 28, № 3. – С. 327–346. – DOI: 10.15372/SJNM20250307. – URL: <https://www.mathnet.ru/sjvm912> (дата обращения: 21.01.2026).

*Привалов Константин Сергеевич. Аспирант кафедры информационных технологий, Финансовый университет при Правительстве РФ. AuthorID: 1321657, SPIN: 5501-7941, ORCID: 0009-0001-5843-2944. qqstik@gmail.com. 125167, Москва, пр-кт Ленинградский, д. 49/2.*

UDC 519.6

DOI:10.25729/ESI.2026.42.2.003

## A modified approach to controlling the parameters of a genetic algorithm based on deep reinforcement learning

**Konstantin S. Privalov**

Financial University under the Government of the Russian Federation,  
Russia, Moscow, [qqstik@gmail.com](mailto:qqstik@gmail.com)

**Abstract.** The relevance of this study is determined by the fact that the efficiency of classical genetic algorithms (GAs) in solving global optimization problems significantly depends on the choice of crossover and mutation probabilities, while fixed parameter values often lead to premature convergence and stabilization of the population in the vicinity of local extrema. The aim of this work is to develop and experimentally evaluate approaches to adaptive control of GA parameters based on artificial neural networks and reinforcement learning. Within a unified mathematical formulation, population state features, a set of actions represented by discrete changes in mutation and crossover probabilities  $p_m$  and  $p_c$ , and a reward function reflecting the improvement in solution quality between generations with a penalty for excessively high mutation are defined. Four algorithmic variants are considered: a classical GA with fixed parameters, a hybrid GA with a neural-network controller (GA+NN), a GA with tabular Q-learning (GA+RL), and the proposed parameter control method based on deep Q-learning, which uses a neural network to approximate the Q-function (GA+DQN). The scientific novelty of the study lies in the integration of a DQN agent into the GA parameter control loop within a formalized “state–action–reward” model and in comparing its efficiency with that of a neural-network controller and tabular Q-learning on continuous optimization problems. Numerical experiments were carried out on the Rastrigin and Schaffer test functions with 20 independent runs for each configuration. The final metrics used were the best objective function value in the

last generation  $f_{min}(T_{max})$  and the best value achieved over the entire run. It is shown that GA+RL provides the greatest improvement in solution quality. The GA+DQN method demonstrates a moderate improvement over the baseline GA, confirming the applicability of deep Q-function approximation to parameter control. The neural-network controller in the considered training scheme shows high sensitivity to parameter settings and, in these experiments, performs worse than the reinforcement learning approaches. The comparison results are presented in the form of convergence plots, an analysis of population diversity indicators, and a summary table.

**Keywords:** genetic algorithm, adaptive parameter control, reinforcement learning, hybrid evolutionary algorithms

## References

1. Goldberg D.E. Genetic Algorithms in Search, Optimization, and Machine Learning. Reading, MA, Addison-Wesley, 1989, 432 p.
2. Holland J.H. Adaptation in Natural and Artificial Systems. Ann Arbor, MI, University of Michigan Press, 1975, 183 p.
3. Fogel D.B. Evolutionary Computation: Toward a New Philosophy of Machine Intelligence. 3rd ed. Hoboken, NJ, IEEE Press, 2006, 296 p.
4. Wolpert D.H., Macready W.G. No Free Lunch Theorems for Optimization. IEEE Transactions on Evolutionary Computation, 1997, vol. 1, no. 1, pp. 67–82.
5. Rastrigin L. A. O skhodimosti sluchajnoogo poiska pri ehkstreml'nom upravlenii mnogoparametricheskimi sistemami [On the convergence of random search in extremal control of multi-parameter systems], Avtomatika i telemekhanika [Automation and remote control], 1963, vol. 24, pp. 1337–1342.
6. Zhang J., Liao S., Lee S. The use of neural networks for adaptive optimization problems in large dimensions, Applied Soft Computing, 2020, vol. 90, art. 106187.
7. Privalov K. S. Gibridnye metody optimizatsii: adaptivnoe upravlenie evolyutsionnym protsessom s ispol'zovaniem iskusstvennykh nejronnykh setey [Hybrid optimization methods: adaptive control of the evolutionary process using artificial neural networks], Inzhenernyj vestnik Dona [Engineering bulletin of the Don], 2025, no. 3, available at: <http://www.ivdon.ru/ru/magazine/archive/n3y2025/9910> (accessed: 12/06/2025).
8. Privalov K. S. Obucheniye s podkrepleniem v adaptivnom upravlenii parametrami geneticheskogo algoritma [Reinforcement learning in adaptive control of genetic algorithm parameters], Inzhenernyj vestnik Dona [Engineering Bulletin of the Don], 2025, no. 8, available at: <http://www.ivdon.ru/ru/magazine/archive/n8y2025/10315> (accessed: 12/06/2025).
9. Sutton R. S., Barto A. G. Reinforcement learning: an introduction, 2nd ed., Cambridge, MA, The MIT Press, 2018, 552 p.
10. Mnih V., Kavukcuoglu K., Silver D., et al. Human-level control through deep reinforcement learning, Nature, 2015, vol. 518, no. 7540, pp. 529–533.
11. Sharma M., Komninos A., López-Ibáñez M., et al. Deep reinforcement learning based parameter control in differential evolution, GECCO '19: Proceedings of the Genetic and Evolutionary Computation Conference, Prague, ACM, 2019, pp. 709–717.
12. Petrosov D.A., Andriyanov N.A., Alyunov A.N., Nezhdanov E.V. Predstavleniye dannykh o sostoyanii populyatsii i obucheniye iskusstvennoy neyronnoy seti v zadache upravleniya rabotoy geneticheskim algoritmom [Population state data representation and training of an artificial neural network for controlling a genetic algorithm]. Ekonomika. Informatika [Economics. Computer science], 2023, vol. 50, no. 4, pp. 924–935, DOI: 10.52575/2712-746X-2023-50-4-924-935, available at: <https://econom-inform-journal.ru/index.php/journal/article/view/330> (accessed: 01/21/2026).
13. Petrosov D.A., Zelenina A.N. Model' iskusstvennoy neyronnoy seti dlya resheniya zadachi upravleniya geneticheskim algoritmom s primeneniyyem matematicheskogo apparata teorii setey Petri [Artificial neural network model for solving the problem of genetic algorithm control using the mathematical apparatus of Petri net theory]. Modelirovaniye, optimizatsiya i informatsionnyye tekhnologii [Modeling, optimization and information technology], 2020, vol. 8, no. 4, DOI: 10.26102/2310-6018/2020.31.4.031, available at: <https://moitvvt.ru/ru/journal/pdf?id=877> (accessed: 01/21/2026).
14. Petrosov D.A., Surova N.Yu., Polyakov A.V. Pravila primeneniya razrushayushchey sposobnosti operatorov geneticheskogo algoritma v zadache strukturno-parametricheskogo sinteza imitatsionnykh modeley biznes-protsessov [Rules for applying the destructive ability of genetic algorithm operators in the problem of structural-parametric synthesis of business process simulation models]. Modelirovaniye, optimizatsiya i informatsionnyye tekhnologii [Modeling, optimization and information technology], 2023, vol. 11, no. 4, DOI: 10.26102/2310-6018/2023.43.4.013, available at: <https://moitvvt.ru/ru/journal/pdf?id=1463> (accessed: 01/21/2026).
15. Sherstnev P.A., Semenkin E.S. SelfCSHAGA: samokonfiguriruyemyy geneticheskiy algoritm optimizatsii s adaptatsiyey na osnove istorii uspekha [SelfCSHAGA: self-configuring genetic optimization algorithm with

adaptation based on success history]. Vestnik MGTU im. N.E. Baumana. Seriya Priborostroyeniye [Bauman MSTU Bulletin. Series "instrument engineering"], 2025, no. 2 (151), pp. 122–139, EDN: TSKBOX. Available at: <https://vestnikprib.bmstu.ru/catalog/icec/sysan/1363.html> (accessed: 01/21/2026).

16. Sakhno M.Yu. Adaptivnyy geneticheskiy algoritm s optimal'noy rekombinatsiyey dlya zadachi sostavleniya raspisaniy s uchetom raskhoda energii [Adaptive genetic algorithm with optimal recombination for scheduling problems with energy consumption]. Sibirskiy zhurnal vychislitel'noy matematiki [Siberian journal of computational mathematics], 2025, vol. 28, no. 3, pp. 327–346, DOI: 10.15372/SJNM20250307, available at: <https://www.mathnet.ru/sjvm912> (accessed: 01/21/2026).

**Privalov Konstantin Sergeevich.** *Postgraduate student of information technology department, Financial University under the Government of the Russian Federation. AuthorID: 1321657, SPIN: 5501-7941, ORCID: 0009-0001-5843-2944. qqstik@gmail.com. 125167, Moscow, Leningradsky Avenue 49/2.*

*Статья поступила в редакцию 15.12.2025; одобрена после рецензирования 22.01.2026; принята к публикации 25.05.26.*

*The article was submitted 12/15/2025; approved after reviewing 01/22/2026; accepted for publication 05/25/2026.*

## **Анализ битемпоральных изображений системой управления коллаборативным роботом-манипулятором для определения вновь появившихся объектов в поле подсистемы технического зрения**

**Калушев Константин Александрович, Макаров Илья Андреевич**

Национальный исследовательский ядерный университет «МИФИ»,

Россия, Москва, *konstantin.kalushev@gmail.com*

**Аннотация.** Одной из задач, относящихся к созданию интерактивного коллаборативного робота-манипулятора, является темпоральный анализ рабочей сцены, то есть определение порядка появления (выбытия) объектов в поле технического зрения. Традиционно, данный вопрос рассматривался применительно к спутниковым снимкам и недостаточно прорабатывался в литературе в отношении сцен, находящихся на расстоянии около 1 м от камеры. Вместе с тем, анализ рабочей сцены на основе битемпоральных изображений является актуальной областью исследований в контексте развития робототехники в целом и физического искусственного интеллекта в частности. Создание качественных темпоральных масок изменения рабочей сцены позволяет определить контуры и геометрические центры новых объектов для последующего захвата роботом-манипулятором. Качественная темпоральная маска не должна иметь ложно определенных областей изменений (объектов изменений, которых на самом деле не существует), но при этом позволять четко обрисовывать контуры истинных объектов изменений рабочей сцены. В статье осуществлена математическая постановка задачи темпорального анализа и на ее базе предложен метод создания темпоральных масок областей изменений на основе дифференцирования изображений «до» и «после», комбинирующий классические методы технического зрения и нейросетевую сегментационную модель SAM (Segment Anything Model). Новизна предлагаемого подхода заключается в применении к дифференцированному изображению не алгебраической обработки, а его сегментация на две области (область изменений и область без изменений) с использованием нейросетевой сегментационной модели. Предложенный подход сопоставлялся с алгебраическими методами создания темпоральных масок (Change Vector Analysis – CVA и Slow Feature Analysis – SFA) и использованием нейросетевой архитектуры многослойного перцептрона (внешний слой из 12 нейронов, внутренний слой из 512 нейронов, наружный слой из 1 нейрона). Продемонстрировано, что предложенный подход позволяет генерировать качественные маски изменений для разнообразных объектов на большом количестве фонов (включая пестрые), чего сложно добиться приведенными для сопоставления методами. Вместе с тем, предложенный подход может быть реализован «на лету», то есть в реальном времени работы оператора-робота, только при наличии графического ускорителя (Graphics Processing Unit – GPU).

**Ключевые слова:** коллаборативный робот, битемпоральные изображения, SAM, бинарные маски изменений

**Цитирование:** Калушев К.А. Анализ битемпоральных изображений системой управления коллаборативным роботом-манипулятором для определения вновь появившихся объектов в поле подсистемы технического зрения / К.А. Калушев, И.А. Макаров // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 42-54. – DOI:10.25729/ESI.2026.42.2.004.

**Введение.** Согласно данным International Federation of Robotics, промышленные коллаборативные роботы набирают все большую популярность и увеличивают присутствие на рынке, в частности, количество новых установок таких роботов в 2024 году по сравнению с предыдущим годом выросло на 12.9%, а доля коллаборативных роботов в общем количестве установленных роботов увеличилась с 2.8% в 2017 году до 11.9% в 2024 году [1]. Традиционно, системы управления коллаборативными роботами-манипуляторами построены на принципе «от точки к точке», то есть требуется прямо программировать все движения робота, что ограничивает сферу использования, существенно расширить которую возможно за счет интеллектуализации систем управления.

Эволюция коллаборативной робототехники привела к появлению понятия «интерактивный коллаборативный робот» [2], под которым подразумевается машина, обладающая элементами искусственного интеллекта и развитой информационно-сенсорной

системой, что позволяет выступать партнером человека при выполнении самых различных задач. Ключевая особенность системы управления интерактивным коллаборативным роботом – максимально полное восприятие окружающей среды, что, в конечном итоге, позволит качественно планировать действия машины в ответ на команды оператора.

Восприятие внешней среды достигается, прежде всего, через систему технического зрения, которая решает две ключевые задачи – определение объектов интереса (англ. – object detection) [3, 4] и сегментацию (англ. – segmentation) рабочей области [5, 6] с целью планирования последующих манипуляционных операций. К дополнительным задачам может относиться определение глубины изображения для расширенного понимания рабочей сцены (например, используя SwiftDepth++ [7], представляющую собой легкую модель оценки глубины, которая обеспечивает конкурентоспособные результаты при сохранении низкого уровня вычислительных затрат).

Несмотря на общий прогресс технического зрения в робототехнике, на сегодня недостаточно проработанной остается задача темпорального анализа рабочей сцены, цель которого – достижение понимания системой управления коллаборативным роботом порядка появления (выбытия) объектов на рабочей сцене. На практике темпоральное восприятие рабочей сцены может помочь оператору формулировать команды с компонентом временной последовательности, такие, как «возьми последнее упавшее яблоко», «убери со стола все предметы, кроме последнего».

В настоящей статье предложен подход к определению новых объектов в поле технического зрения, особенностью которого выступает комбинация классических методов машинного зрения (вычитание изображений) и нейросетевых инструментов для сегментации и создания темпоральных масок. Специфика решения задачи определения изменений на изображении рабочей области коллаборативного робота-манипулятора – повышенные требования к производительности (необходимость работы «на лету», с соответствующим показателем FPS) и к качеству масок новых объектов, которые могут использоваться для выработки стратегии их захвата.

**1. Обзор литературы.** В решении задачи определения изменений на изображениях можно выделить два принципиальных подхода [8]: отслеживание попиксельных изменений (включая алгебраические, трансформационные и классификационные методы) и отслеживание изменений объектов на изображении (например, посредством кластеризации изображений на такие объекты).

Вопросы анализа изменений на изображениях получили наиболее глубокое рассмотрение применительно к анализу изображений удаленных объектов (remote sense detection), прежде всего анализу спутниковых снимков. Классическим алгебраическим методом выступает анализ вектора изменений (англ. – Change Vector Analysis – CVA), суть которого сводится к определению какой-либо метрики расстояния (например, евклидоваго расстояния) между двумя корреспондирующими пикселями изображений «до» и «после» с последующем вычислении маски на ее основе для изображения в целом (например, как это сделано в работах [9, 10]). Применение нашла также адаптация подхода анализа наименее изменяемых компонентов (англ. - Slow Feature Analysis – SFA) для целей анализа удаленных объектов (например, как в [11]), суть которого сводится к определению набора функций, которые извлекают наименее изменяющиеся признаки многомерного входного сигнала, такого, как фотографическое изображение. Существует множество реализаций SFA для различных применений [12], в том числе на основании фреймворка Python MDP [13].

Анализ изменений на изображениях нашел свое развитие в применении нейросетевых методов. Например, в работе [14] предложена архитектура IDJANet, интегрирующая механизмы деформируемого внутреннего внимания (англ. – deformable self-attention) и кросс-

внимания (англ. – cross-attention), а в работе [15] – модель HFNet для извлечения признаков темпоральных изменений, использующая двухкомпонентный энкодер для связанных и дифференцирующих признаков.

Реже в литературе рассматриваются методы определения изменений на изображениях «открытого мира». Например, в статье [16] предлагается метод определения изменений в изображениях, полученных с камеры мобильного робота-патрульного. В статье [17] рассматривался метод определения изменений при одновременном осуществлении семантической сегментации. Метод базируется на архитектуре сверточной нейронной сети U-net, используя один энкодер и два декодера для осуществления одновременной сегментации снимков «до» и «после» и генерации маски для выявления изменений на изображениях.

Вопросы определения изменений на 3D-сцене, сопоставимой с рабочей областью коллаборативного робота-манипулятора, рассматривались в статье [18], в которой предложен метод SemanticDifference, основанный на 4D гауссовом сплэтинге для 3D-представления сцен «до» и «после» на основе множества снимков рабочей сцены. Предложено осуществлять рендеринг изображения «после» из точки, где располагалась камера «до», и после этого сопоставлять изображения на базе выделения потенциальных сегментов, в которых могли произойти изменения. Принципиальным отличием от предлагаемого в настоящей статье подхода выступает построение полной 3D-модели рабочей области на основании нескольких снимков, что требует соответствующих вычислительных ресурсов и не подходит для работы «на лету».

Методы темпорального анализа рабочей сцены робота-манипулятора к настоящему моменту широкого отражения в литературе не нашли.

**2. Постановка задачи.** Пусть имеются два битемпоральных изображения  $I_1 \subseteq R^{3 \cdot H \cdot W}$  и  $I_2 \subseteq R^{3 \cdot H \cdot W}$ , где 3 представляет собой количество каналов,  $H$  – высоту изображения в пикселях,  $W$  – ширину изображения в пикселях. При этом пусть  $C_1 = \{c_1, c_2, \dots, c_N\}$  представляет собой семантическое множество объектов на  $I_1$ , а  $C_2 = \{c_1, c_2, \dots, c_M\}$  – на  $I_2$ .

Под совокупностью новых объектов на  $I_1$  будет пониматься подмножество  $C' = C_2 / C_1$ , то есть подмножество, состоящее из элементов:

$$C' = \{c_{N+1}, \dots, c_M\} \quad (1)$$

Задача определения маски новых объектов на  $I_2$  состоит в определении:

$$M(x, y) \in \{0, 1\}^{1 \cdot H \cdot W}, \quad (2)$$

где значение 1 присваивается всем пикселям  $(x, y)$ , таким, что

$$I_2(x, y) \in C'. \quad (3)$$

Пикселям, не удовлетворяющим данному условию, присваивается значение 0.

Ключевыми особенностями задачи определения новых объектов в поле технического зрения робота-манипулятора выступают:

1. Необходимость максимально геометрически точного определения масок объектов для целей последующего формирования стратегии захвата манипулятором (gripping strategy planning).

2. Расположение камеры технического зрения стационарно (вибрации также отсутствуют). Камера технического зрения может располагаться в фиксированном (над рабочей сценой) либо в квази-фиксированном положении (непосредственно рядом со схватом робота на конечном звене, в позиции eye-in-hand).

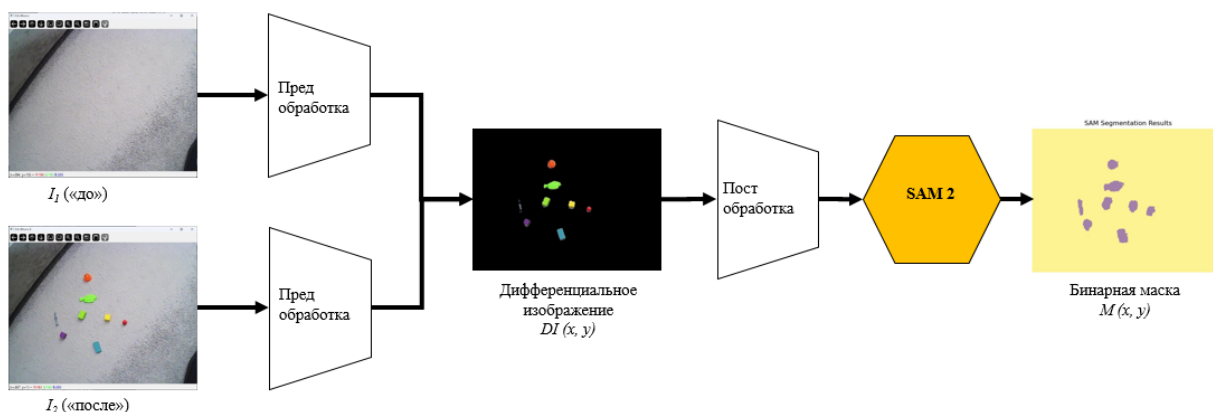
3. Расстояние от объектива камеры до основной рабочей поверхности фона составляет около 1 метра.

4. Отсутствие резких перепадов освещения между кадрами (например, сценариев «день-ночь», включение-выключение точечного или фонового источника освещения).

5. Возможность использовать только коммерчески доступные ЭВМ, целесообразные с экономической точки зрения (например, если речь идет об одноплатном компьютере, то не производительнее / не дороже NVIDIA Jetson Orin Nano).

**3. Методология.** Предлагается совместить классические методы компьютерного зрения (для предобработки, формирования дифференциального изображения алгебраическим методом дифференцирования изображений, и постобработки) с последующей сегментацией с использованием нейросетевых моделей.

Подход, предлагаемый к реализации автором, описан на рис. 1 и состоит из следующих последовательных шагов. Прежде всего, осуществляется предобработка  $I_1$  и  $I_2$  с целью выравнивания их взаимной яркости и контрастности изображений. Предобработка осуществляется с помощью тривиальных методов, в связи с чем в настоящей статье не описывается.



**Рис. 1.** Структурная схема предложенного подхода к определению изменений на изображениях

Обработанные  $I_1$  и  $I_2$  используются для формирования дифференциального изображения  $DI(x, y)$  следующим образом. Определяются расстояния между соответствующими пикселями  $I_1$  и  $I_2$ . В общем виде матрицу расстояний можно представить, как:

$$D(x, y) = \|I_1 - I_2\|, \quad (4)$$

где  $\|I_1 - I_2\|$  представляет собой оценку расстояния между соответствующими пикселями двух изображений с помощью одной из метрик, таких, как евклидово расстояние, манхэттенское расстояние или косинусная близость.

Далее непосредственно формируется дифференциальное изображение рабочей области на основании подхода с применением порогового значения  $\tau$

$$DI(x, y) = \begin{cases} I_2(x, y), & \text{если } D(x, y) > \tau \\ 0, & \text{в иных случаях} \end{cases} \quad (5)$$

В связи с наличием на изображении дефектов, снижающих качество будущей бинарной маски, проводится постобработка. В частности, устраняются «внутренние» пустые пиксели в областях расположения семантических объектов из  $C'$  (см. рис. 2). Для этого используется одна из реализаций метода «наводнения» (англ. - flood fill).

На рисунке 2 слева представлено изображение до исключения внутренних областей, справа – после. Полученное после постобработки улучшенное дифференциальное изображение  $DI'(x, y)$  используется в качестве входящего для нейросетевой сегментационной модели. Сегментационная модель (Segment Anything Model – SAM) [19] представляет собой базовую модель (англ. – foundation model), которая впервые была опубликована в 2023 году, а также соответствующий набор данных из более чем 1 млрд. масок для более чем 11 млн. изображений.



**Рис. 2.** Результат исключения внутренних областей

Как и другие базовые модели в области ИИ, SAM способна выходить за рамки тренировочного набора данных и осуществлять сегментацию произвольных изображений без предварительного обучения (англ. – zero-shot). В 2024 году была представлена модель SAM-2 [20], отличающаяся как повышенной производительностью при сегментации изображений (заявляется увеличение FPS в 6 раз), так и возможностью сегментации видео. В настоящей работе мы ссылаемся на обе модели, как на SAM. В задачах определения новых объектов в поле технического зрения SAM формирует бинарную маску  $M(x, y)$  для областей изменения изображений  $DI(x, y)$  (то есть областей, в которых значения пикселей на  $I_1$  и  $I_2$  отличаются от порогового значения).

**4. Эксперимент.** Далее представлено описание экспериментов, проведенных с использованием предложенного подхода к определению новых объектов в поле технического зрения коллаборативного робота-манипулятора. Основной эксперимент сводился к экспертной оценке качественных результатов формирования масок расположения новых объектов.

#### 4.1. Технология экспериментов.

Оценка эффективности предложенного подхода осуществлялась на ЭВМ в трех конфигурациях, описанных в таблице 1. Использование нескольких конфигураций обусловлено спецификой задачи – определением подхода, который может практически использоваться для системы управления роботом-манипулятором, вычислительные ресурсы которой ограничены, а определение масок новых объектов должно осуществляться «на лету».

**Таблица 1.** Конфигурации оборудования для тестирования

Конфигурация	CPU	RAM	GPU
1	11th Gen Intel Core i3-1115G4 (3.00 GHz)	8,0 Гб	Отсутствует (встроенная видеокарта Intel UHD Graphics)
2	13 <sup>th</sup> Gen Intel Core i7-13700H (2.40 GHz)	16,0 Гб	Отключен (встроенная Intel Iris Xe Graphics)
3	13 <sup>th</sup> Gen Intel Core i7-13700H (2.40 GHz)	16,0 Гб	NVIDIA GeForce RTX 4070 Laptop GPU (8,0 Гб)

Для осуществления экспериментов был написан код на языке Python. Код, относящийся к сегментационной модели SAM, использовал соответствующую библиотеку от компании Ultralytics. Использовались веса модели от SAM-2 [20] различных типов.

Нами не найдено опубликованных наборов данных с битемпоральными масками изменения рабочей сцены робота-манипулятора (то есть для закрытой стационарной сцены с расположением камеры на высоте около 1 м над ней). Из ближайших аналогов следует

отметить набор данных Panoramic Change Detection (PCD) [21] для выявления изменений в открытой среде (ландшафты после цунами в Японии). В связи с этим тестирование проводилось на качественном уровне. Предлагаем под качественной битемпоральной маской понимать маску, которая (а) имеет четкие контуры, (б) не имеет внутренних артефактов (областей, отмеченных как области без изменений, в которых изменения фактически были) во внутренней области и (в) не имеет внешних артефактов (областей отмеченных ложных изменений).

**4.2. Результаты экспериментов.** Осуществлены (1) количественный тест, направленный на определение производительности предложенного подхода по определению новых объектов в поле технического зрения робота на различных конфигурациях оборудования, и (2) качественный тест, нацеленный на подтверждение способности предложенного подхода создавать адекватные битемпоральные маски для различных объектов и фонов.

Для теста 1 использовались конфигурации оборудования, описанные в таблице 1 (конфигурации 1 и 2 фактически представляют собой работу на CPU, конфигурация 3 – на GPU). Результаты Теста 1 представлены в таблице 2.

**Таблица 2.** Результаты теста 1 – время на сегментацию кадра с помощью SAM (в миллисекундах для различных весов)

Модель SAM	Конфигурация 1	Конфигурация 2	Конфигурация 3
SAM 2.1 tiny	3020	950 (нет распознавания)	67 (нет распознавания)
SAM 2.1 small	3850	1030	75
SAM 2.1 base	6500	1820	116
SAM 2.1 large	15850	4640	268

Результаты Теста 1 демонстрируют, что реализовать систему технического зрения робота-манипулятора, работающую «на лету» фактически (то есть с временем на сегментацию менее 1000 мс) возможно только с использованием GPU. Необходимо обратить внимание, что на практике при использовании только CPU даже по сравнению с представленными в таблице 1 результатами время обработки может резко и существенно возрасти (как показали эксперименты, в два раза) при увеличении загрузки CPU общесистемными задачами.

Тест 2 заключался в исследовании распознавания различных объектов на фонах различного типа (монотонный, цветной и пестрый) с использованием конфигурации 3 (см. выше). Выбор конкретных объектов был продиктован их цветовой палитрой, с целью необходимости убедиться в работоспособности метода в различных потенциальных окружениях.

Практические результаты экспериментов представлены на таблице 3 ниже. Для иллюстративных целей в таблице 3 представлены не бинарные маски областей изменений (см. образец на рисунке 1), а обратные бинарные маски  $M_{rev}(x, y) = \sim M(x, y)$ , закрывающие черным цветом области  $I_2$ , в которых изменений нет.




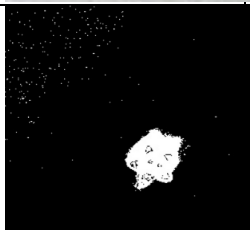
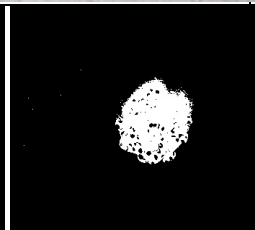


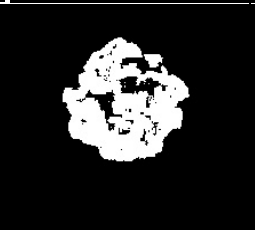
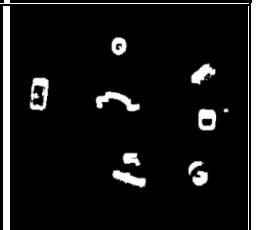

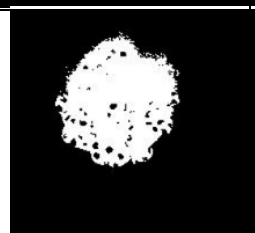
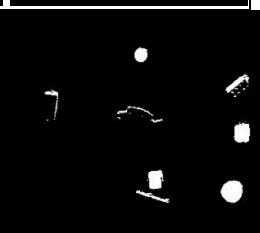
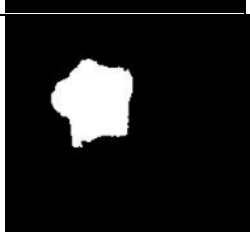
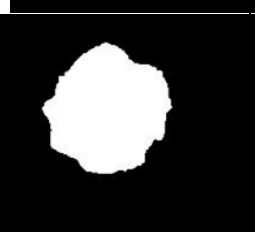
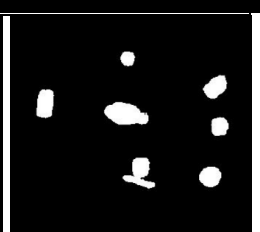
Результаты теста 2, полученные с использованием предложенного метода, сопоставлялись с результатами, полученными при реализации методов Change Vector Analysis (CVA) по аналогии с тем, как это было сделано в [9, 10], и одной из возможных реализаций метода Slow Feature Analysis (SFA) на основе фреймворка Python MDP, как это было сделано в [11].






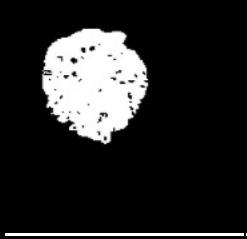
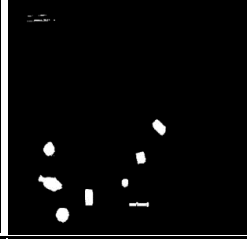


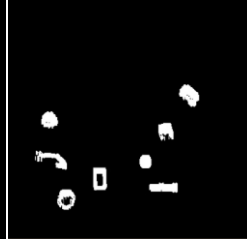

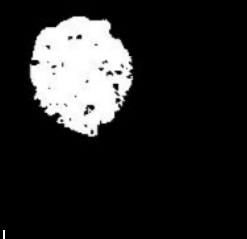
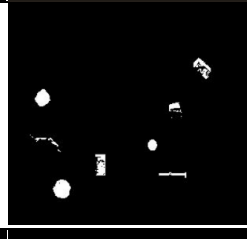
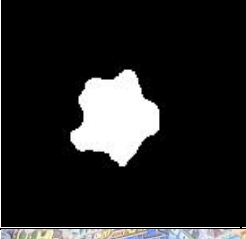





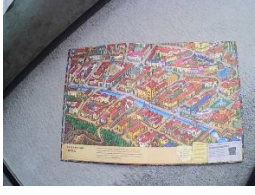
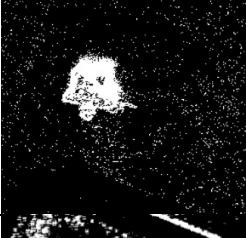
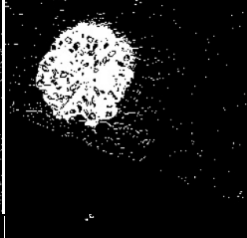
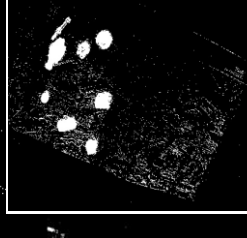
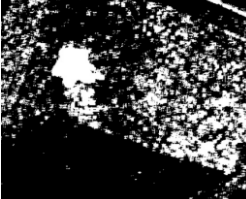
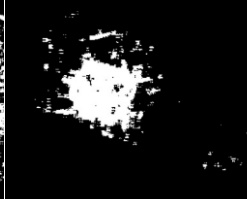
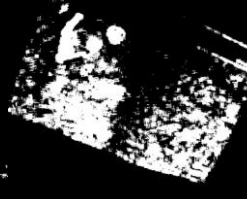
Дополнительные результаты получены и использованием нейронной сети прямого распространения, построенной по архитектуре многослойного перцептрона (Multi-layer Perceptron – MLP): внешний слой из 12 нейронов, внутренний слой из 512 нейронов, наружный


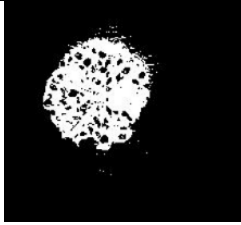

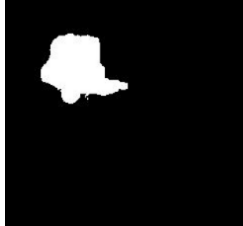
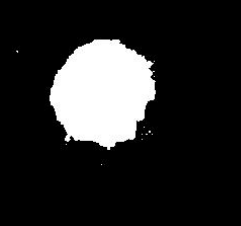

слой из 1 нейрона (использовался как классификатор – были ли изменения в данном пикселе). На внешний слой обучения модели попиксельно подавались векторы, состоящие из нормированных значений пикселей изображения «до», нормированных значений пикселей изображения «после», разницы в значениях нормированных пикселей и квадрата такой разницы. Метки классов (0 – изменения в пикселе не было, 1 – изменение в пикселе было) брались из битемпоральной маски, созданной с применением изложенного в настоящей статье метода, качество которой было признано наилучшим.

Обращаем внимание, что мы не проводили количественный тест затрат машинного времени для методов сопоставления, аналогичный тесту 1 для предложенного подхода с использованием SAM, в связи с тем, что их реализация в целом требует значительно меньшей производительности оборудования (для любого из приведённых в таблице 3 изображений менее 1 000 мс) по сравнению с использованием нейросети, для работы «на лету» которой необходимо наличие GPU.

**Таблица 3.** Качественные результаты тестирования


Фон	Метод	Объект (а)	Объект (б)	Объект (в)
Оригинальное изображение				
Монотонный	CVA			
	SFA			
	MLP			
	Наш			

Фон	Метод	Объект (а)	Объект (б)	Объект (в)	
Оригинальное изображение					
Цветной		CVA			
	SFA				
	MLP				
	Наш				
Оригинальное изображение					
Пестрый		CVA			
	SFA				

Фон	Метод	Объект (а)	Объект (б)	Объект (в)
	MLP			
	Наш			


Проведенным экспериментом продемонстрировано, что на монотонном фоне возможно созданием маски битемпоральных изменений с использованием любого метода (маски, созданные с помощью использованной реализации метода SFA хуже для маленьких объектов). Однако при усложнении фона (пестрый) альтернативные методы показывают резкое визуально очевидное ухудшение качества масок. Таким образом, продемонстрировано, что при соответствующем выборе порогового значения (параметр  $\tau$ ) предложенным в настоящей статье методом удастся создать высокого качества битемпоральные маски на сложных типах фона, даже на пестром (с ухудшением качества масок по сравнению с более простыми типами фонов).

Отметим, что некачественные битемпоральные маски не позволяют выделять контур конкретного объекта интереса (красная линия на рис. 3а) и делают невозможным определить геометрический центр объекта (красная точка на рис. 3б) с целью последующего захвата роботом.



**Рис. 3.** Некачественные битемпоральные маски: (а) Внешнее зашумление не позволяет определить конкретный объект интереса и (б) Некорректные контуры объекта искажают положение геометрического центра фигуры (например, А и В)

Нами проведено практическое тестирование возможности захвата объекта интереса с помощью представленного метода. Тестирование осуществлялось с использованием демонстративного робота SCARA, построенного одним из авторов и описанного в статье [22]. Использование качественных битемпоральных масок изменений (без внешних и внутренних шумов на изображениях), позволяет легко определять контуры объектов интереса и находить их геометрические центры (см. рисунок 4).



**Рис. 4.** Качественные битемпоральные маски (а) позволяют осуществить (б) ориентирование схвата робота-манипулятора и (в) захват «нового» объекта на рабочей сцене

Описанный демонстративный результат достигнут с учетом следующих принципиальных особенностей (хоть и практически приемлемых для среды функционирования коллаборативного робота-манипулятора):

1. Наличие теней от самих объектов из-за внешних источников освещения (специальное освещение рабочей сцены не использовалось) может привести к искажению контуров объектов на дифференциальном изображении и, как следствие, невозможности создания точной бинарной маски,

2. Внешние тени (например, от фигуры оператора, находящегося рядом с роботом) могут признаваться в качестве объектов изменения, полностью деструктурируя картину распознавания,

3. Изменение общей освещенности рабочей сцены (например, из-за включения освещения в помещении, в котором функционирует робот), также может привести к искажению контуров объектов, хотя и не всегда критическому.

**Заключение.** В настоящей статье предложен и экспериментально апробирован подход к определению новых объектов в поле технического зрения коллаборативного робота-манипулятора на основании битемпоральных изображений с минимальной задержкой по времени, то есть для работы в реальных условиях «на лету». Особенностью предлагаемого подхода выступает совмещение методов классического технического зрения для создания дифференциального изображения и последующей нейросетевой сегментации для генерации бинарной маски областей изменения битемпоральных изображений. С учетом ограничений и особенностей, присущих техническому зрению роботов-манипуляторов, подход показал свою практическую применимость для различных типов фонов рабочей области робота, позволяя четко определять контуры и геометрические центры «новых» объектов с целью последующего захвата манипулятором. Вместе с тем, при его использовании необходимо учитывать, что по принципу «на лету» он может быть реализован только на ЭВМ с GPU.

#### Список источников

1. World Robotics 2025 Report, International Federation of Robotics. Available at: [https://ifr.org/downloads/press\\_docs/PressConference2025\\_presentation.pdf](https://ifr.org/downloads/press_docs/PressConference2025_presentation.pdf) (accessed: 10/20/2025).
2. Ющенко А.С. Коллаборативная робототехника и человеческий фактор / А.С. Ющенко // Актуальные проблемы психологии труда, инженерной психологии и эргономики. – Москва: Институт психологии РАН, 2020. – С. 83-103.
3. Бадика Е.М. Модель инициализации промышленных роботов с помощью обнаружения объектов на основе глубокого обучения / Е.М. Бадика, В.П. Кузьменко // *Флагман науки*, 2023. – № 9(9). – С. 377-380.
4. Dong Y.J., Cheng J., Meng L. Object Recognition and Grasping for Baxter Dual-Arm Robot Based on YOLOv8\_OBB. Chinese Control Conference (CCC), Chongqing, China, 2025, pp. 4662-4667, DOI:10.23919/CCC64809.2025.11179705.
5. Матвеев В.Д. Разработка модели семантической сегментации RTC-SAM для определения препятствий на пути мобильного робота / В.Д. Матвеев, А.Е. Архипов, И.С. Фомин // *Известия ЮФУ. Технические науки*, 2025. – № 2(244). – С. 212-220.

6. Giacchetti M., Guerra E., García F.C. et al. Perception for Collaborative Robots in Pruning Operations. International Conference on Emerging Technologies and Factory Automation (ETFA), Padova, Italy, 2024, pp. 01-04.
7. Дайюб Я. SwiftDepth++: эффективная и легковесная модель для точной оценки глубины / Я. Дайюб, И.А. Макаров // Доклады Российской академии наук. Математика, информатика, процессы управления, 2024. – Т. 520. – № 2. – С. 182-192.
8. Fang H., Guo S., Wang X. et al. Automatic Urban Scene-Level Binary Change Detection Based on a Novel Sample Selection Approach and Advanced Triplet Neural Network. IEEE Transactions on Geoscience and Remote Sensing, 2018, vol. 61, pp. 1-18, DOI: 10.1109/TGRS.2023.3235917.
9. Wen X., Yang X. Change Detection from Remote Sensing Imageries Using Spectral Change Vector Analysis. Asia-Pacific Conference on Information Processing, Shenzhen, China, 2009, pp. 189-192, DOI:10.1109/APCIP.2009.183.
10. Xiaolu S., Bo C. Change Detection Using Change Vector Analysis from Landsat TM Images in Wuhan. Procedia Environmental Sciences, 2011, vol. 11, pp. 238-244, DOI: 10.1016/j.proenv.2011.12.037.
11. Wu C., Du B., Zhang L. Slow Feature Analysis for Change Detection in Multispectral Imagery. IEEE Transactions on Geoscience and Remote Sensing, 2014, vol. 52, pp. 2858-2874, DOI: 10.1109/TGRS.2013.2266673.
12. Song P., Zhao C. Slow Down to Go Better: A Survey on Slow Feature Analysis. IEEE Transactions on Neural Networks and Learning Systems, 2024, vol. 35, pp. 3416-3436, DOI: 10.1109/TNNLS.2022.3201621.
13. Kamal S., Supriya M.H., Pillai P.R.S. Blind source separation of nonlinearly mixed ocean acoustic signals using Slow Feature Analysis. OCEANS 2011 IEEE, 2011, pp. 1-7, DOI: 10.1109/Oceans-Spain.2011.6003620.
14. Ma Q., Jia Y., Gong H. et al. A novel iterative deformable joint attention network for remote sensing image change detection. Multimedia Systems, 2025, DOI: 10.1007/s00530-025-01981-5.
15. Han Y., Li J., Qu Y. et al. HFNet: Semantic and Differential Heterogenous Fusion Network for Remote Sensing Image Change Detection. Journal of Geovisualization and Spatial Analysis, 2024, DOI: 10.1007/s41651-024-00202-3.
16. Choe C., Lee S., Sung N.S. Change Detection for Robotic Patrol System. Eighth IEEE International Conference on Robotic Computing (IRC), 2024, pp. 114-115, DOI: 10.1109/IRC63610.2024.00029.
17. Tsutsui S., Hirakawa T., Yamashita T. et al. Semantic Segmentation and Change Detection By Multi-Task U-Net. IEEE International Conference on Image Processing (ICIP), 2021, pp. 619-623, DOI: 10.1109/ICIP42928.2021.9506560.
18. Huang R. Li. P., Tao H., et al. SemanticDifference: Change Detection with Multi-scale Vision-Language Representation Difference, 2025, DOI: 10.1007/978-981-96-9866-0\_13.
19. Kirillov A., Mintun Eric, Ravi N., et al. Segment Anything. IEEE/CVF International Conference on Computer Vision (ICCV), 2023, pp. 3992-4003, DOI: 10.1109/ICCV51070.2023.00371.
20. Ravi N., Gabeur V., Hu Y.-T. SAM 2: Segment Anything in Images and Videos, 2024, DOI: 10.48550/arXiv.2408.00714.
21. Sakurada K., Okatani T. Change detection from a street image pair using cnn features and superpixel segmentation, available at: [https://www.researchgate.net/publication/301452621\\_Change\\_Detection\\_from\\_a\\_Street\\_Image\\_Pair\\_using\\_CNN\\_Features\\_and\\_Superpixel\\_Segmentation](https://www.researchgate.net/publication/301452621_Change_Detection_from_a_Street_Image_Pair_using_CNN_Features_and_Superpixel_Segmentation).
22. Калушев К.А. Разработка математической модели управления роботом SCARA на базе шаговых двигателей / К.А. Калушев, Л.И. Воронова // Робототехника и техническая кибернетика, 2025. – Т. 13. – № 2. – С. 104-114.

**Калушев Константин Александрович.** Национальный исследовательский ядерный университет «МИФИ», аспирант кафедры №22 «Кибернетика». Научные интересы: системы управления роботами и компьютерное зрение. AuthorID: 1225216, SPIN: 2759-0169, ORCID: 0009-0005-7065-0716, [konstantin.kalushev@gmail.com](mailto:konstantin.kalushev@gmail.com), 115409, Россия, Москва, Каширское шоссе, д. 31

**Макаров Илья Андреевич.** к.т.н., Национальный исследовательский ядерный университет «МИФИ», доцент Центра образовательных программ топ-уровня в области ИИ Института Интеллектуальных Кибернетических Систем. Научные интересы: машинное обучение и компьютерное зрение. AuthorID: 826008, SPIN: 3151-9176, ORCID: 0000-0002-3308-8825, [iatakarov@hse.ru](mailto:iatakarov@hse.ru), 115409, Россия, Москва, Каширское шоссе, д. 31

UDC 004.89, 681.5

DOI:10.25729/ESI.2026.42.2.004

## The analysis of bi-temporal images by a collaborative robot control system to determine new objects in the field of view of the technical vision subunit

Konstantin A. Kalushev, Ilya A. Makarov

National Research Nuclear University “MEPhI”, Russia, Moscow, *konstantin.kalushev@gmail.com*

**Abstract:** One of the tasks associated with developing an interactive collaborative robotic manipulator is temporal analysis of the work scene, i.e., determining the order in which objects appear (and disappear) within the field of view of the vision system. Traditionally, this issue has been considered in the context of satellite imagery and has not been sufficiently addressed in the literature with regard to scenes located approximately 1 m from the camera. At the same time, work scene analysis based on bi-temporal images is a relevant area of research in the context of the development of robotics in general and physical artificial intelligence in particular. Creating high-quality temporal change masks of the work scene makes it possible to determine the contours and geometric centers of new objects for subsequent grasping by the robotic manipulator. A high-quality temporal mask should not contain falsely detected change regions (change objects that do not actually exist), yet should clearly outline the contours of genuine change objects in the work scene. The paper presents a mathematical formulation of the temporal analysis problem and, on its basis, proposes a method for generating temporal change region masks by differentiating “before” and “after” images, combining classical computer vision techniques with the neural network segmentation model SAM (Segment Anything Model). The novelty of the proposed approach lies in applying to the difference image not algebraic processing, but rather its segmentation into two regions (a change region and a no-change region) using a neural network segmentation model. The proposed approach was compared with algebraic methods for creating temporal masks (Change Vector Analysis – CVA and Slow Feature Analysis – SFA) and with the use of a multilayer perceptron neural network architecture (input layer of 12 neurons, hidden layer of 512 neurons, output layer of 1 neuron). It is demonstrated that the proposed approach enables the generation of high-quality change masks for diverse objects against a large number of backgrounds (including cluttered ones), a result that is difficult to achieve with the methods brought for comparison. At the same time, the proposed approach can be implemented “on the fly,” i.e., in real time during robot operator work, only if a Graphics Processing Unit (GPU) is available.

**Keywords:** collaborative robot, bitemporal images, SAM, binary change masks

### References

1. World Robotics 2025 Report, International Federation of Robotics. Available at: [https://ifr.org/downloads/press\\_docs/PressConference2025\\_presentation.pdf](https://ifr.org/downloads/press_docs/PressConference2025_presentation.pdf) (accessed: 10/20/2025).
2. Yushchenko A.S. Kollaborativnaya robototekhnika i chelovecheskiy faktor [Collaborative robotics and the human factor]. Aktual'nyye problemy psikhologii truda, inzhenernoy psikhologii i ergonomiki [Current problems of labor psychology, engineering psychology and ergonomics]. Moscow, Institute of Psychology RAS Publ., 2020, pp. 83-103.
3. Badika E.M., Kuzmenko V.P. Model initsializatsii promyshlennykh robotov s pomoshch'yu obnaruzheniya ob'yektov na osnove glubokogo obucheniya [Initialization model for industrial robots using deep learning-based object detection]. Flagman nauki [Flagman sciences], 2023, no. 9(9), pp. 377-380.
4. Dong Y.J., Cheng J., Meng L. Object Recognition and Grasping for Baxter Dual-Arm Robot Based on YOLOv8\_OBB. Chinese Control Conference (CCC), Chongqing, China, 2025, pp. 4662-4667, DOI:10.23919/CCC64809.2025.11179705.
5. Matveev V.D., Arkhipov A.E., Fomin I.S. Razrabotka modeli semanticheskoy segmentatsii RTC-SAM dlya opredeleniya prepyatstviy na puti mobil'nogo robot [Development of the RTC-SAM semantic segmentation model for obstacle detection along the path of a mobile robot]. Izvestiya YuFU. Tekhnicheskiye nauki [Proceedings of SFU. Technical sciences], 2025, no. 2(244), pp. 212-220.
6. Giacchetti M., Guerra E., García F.C. et al. Perception for Collaborative Robots in Pruning Operations. International Conference on Emerging Technologies and Factory Automation (ETFA), Padova, Italy, 2024, pp. 01-04.
7. Dayyub Y., Makarov I.A. SwiftDepth++: effektivnaya i legkovesnaya model' dlya tochnoy otsenki glubiny [SwiftDepth++: an efficient and lightweight model for accurate depth estimation]. Doklady Rossiyskoy akademii nauk. Matematika, informatika, protsessy upravleniya [Reports of the Russian academy of sciences. Mathematics, computer science, control processes], 2024, vol. 520, no. 2, pp. 182-192.

8. Fang H., Guo S., Wang X. et al. Automatic Urban Scene-Level Binary Change Detection Based on a Novel Sample Selection Approach and Advanced Triplet Neural Network. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, vol. 61, pp. 1-18, DOI: 10.1109/TGRS.2023.3235917.
9. Wen X., Yang X. Change Detection from Remote Sensing Imageries Using Spectral Change Vector Analysis. *Asia-Pacific Conference on Information Processing*, Shenzhen, China, 2009, pp. 189-192, DOI:10.1109/APCIP.2009.183.
10. Xiaolu S., Bo C. Change Detection Using Change Vector Analysis from Landsat TM Images in Wuhan. *Procedia Environmental Sciences*, 2011, vol. 11, pp. 238-244, DOI: 10.1016/j.proenv.2011.12.037.
11. Wu C., Du B., Zhang L. Slow Feature Analysis for Change Detection in Multispectral Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, vol. 52, pp. 2858-2874, DOI: 10.1109/TGRS.2013.2266673.
12. Song P., Zhao C. Slow Down to Go Better: A Survey on Slow Feature Analysis. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, vol. 35, pp. 3416-3436, DOI: 10.1109/TNNLS.2022.3201621.
13. Kamal S., Supriya M.H., Pillai P.R.S. Blind source separation of nonlinearly mixed ocean acoustic signals using Slow Feature Analysis. *OCEANS 2011 IEEE*, 2011, pp. 1-7, DOI: 10.1109/Oceans-Spain.2011.6003620.
14. Ma Q., Jia Y., Gong H. et al. A novel iterative deformable joint attention network for remote sensing image change detection. *Multimedia Systems*, 2025, DOI: 10.1007/s00530-025-01981-5.
15. Han Y., Li J., Qu Y. et al. HFNet: Semantic and Differential Heterogenous Fusion Network for Remote Sensing Image Change Detection. *Journal of Geovisualization and Spatial Analysis*, 2024, DOI: 10.1007/s41651-024-00202-3.
16. Choe C., Lee S., Sung N.S. Change Detection for Robotic Patrol System. *Eighth IEEE International Conference on Robotic Computing (IRC)*, 2024, pp. 114-115, DOI: 10.1109/IRC63610.2024.00029.
17. Tsutsui S., Hirakawa T., Yamashita T. et al. Semantic Segmentation and Change Detection By Multi-Task U-Net. *IEEE International Conference on Image Processing (ICIP)*, 2021, pp. 619-623, DOI: 10.1109/ICIP42928.2021.9506560.
18. Huang R. Li. P., Tao H., et al. SemanticDifference: Change Detection with Multi-scale Vision-Language Representation Difference, 2025, DOI: 10.1007/978-981-96-9866-0\_13.
19. Kirillov A., Mintun Eric, Ravi N., et al. Segment Anything. *IEEE/CVF International Conference on Computer Vision (ICCV)*, 2023, pp. 3992-4003, DOI: 10.1109/ICCV51070.2023.00371.
20. Ravi N., Gabeur V., Hu Y.-T., SAM 2: Segment Anything in Images and Videos, 2024, DOI: 10.48550/arXiv.2408.00714.
21. Sakurada K., Okatani T. Change detection from a street image pair using cnn features and superpixel segmentation, available at: [https://www.researchgate.net/publication/301452621\\_Change\\_Detection\\_from\\_a\\_Street\\_Image\\_Pair\\_using\\_CNN\\_Features\\_and\\_Superpixel\\_Segmentation](https://www.researchgate.net/publication/301452621_Change_Detection_from_a_Street_Image_Pair_using_CNN_Features_and_Superpixel_Segmentation).
22. Kalushev K.A., Voronova L.I. Razrabotka matematicheskoy modeli upravleniya robotom SCARA na baze shagovykh dvigateley [Development of a mathematical model for controlling an SCARA robot based on stepper motors]. *Robototekhnika i tekhnicheskaya kibernetika [Robotics and technical cybernetics]*, 2025, vol. 13, no. 2, pp. 104-114.

**Kalushev Konstantin Aleksandrovich.** *National Research Nuclear University «MEPhI», postgraduate student of Department No. 22 «Cybernetics», Research interests: robot control systems and computer vision. AuthorID: 1225216, SPIN: 2759-0169, ORCID: 0009-0005-7065-0716, konstantin.kalushev@gmail.com. 31, Kashirskoe Highway, Moscow, 115409 Russia.*

**Makarov Ilya Andreevich.** *Ph.D., National Research Nuclear University «MEPhI», associate professor of the Center of top-level educational programs in AI of the Institute of Intellectual Cybernetic Systems. Research interests: machine learning and computer vision. AuthorID: 826008, SPIN: 3151-9176, ORCID: 0000-0002-3308-8825, iamakarov@hse.ru. 31, Kashirskoe Highway, Moscow, 115409 Russia.*

*Статья поступила в редакцию 15.11.2025; одобрена после рецензирования 10.12.2025; принята к публикации 12.05.2026.*

*The article was submitted 11/15/2025; approved after reviewing 12/10/2025; accepted for publication 05/12/2026.*

УДК 004.93'12

DOI:10.25729/ESI.2026.42.2.005

## Разработка метода идентификации транспортного средства

Горский Максим Сергеевич, Мосева Марина Сергеевна

Московский технический университет связи и информатики,  
Россия, Москва, *m.s.gorskiy@edu.mtu.ru*

**Аннотация.** Целью статьи является описание разработки и обучения модели, способной классифицировать автомобили по маркам и моделям на основе изображений, а также интерфейса для удобного взаимодействия с моделью. Новизна работы подтверждается использованием современных методов идентификации транспортных средств для их тонкой классификации. В статье представлены три раздела, каждый из которых охватывает ключевые аспекты исследования. В рамках первого раздела выполнен анализ предметной области, в котором рассмотрены существующие методы идентификации транспортных средств, включая технологии на основе лидарных данных, а также методы, использующие изображения и видео. Особое внимание уделено анализу современных подходов к классификации транспортных средств по маркам, моделям и другим атрибутам. Этот анализ позволил выявить сильные и слабые стороны различных подходов и обосновать выбор архитектур глубокого обучения для дальнейшего исследования. Во втором разделе описан собранный набор данных с детальной маркировкой по маркам и моделям, использованный для исследования. Проведено сравнение трех моделей машинного обучения по различным метрикам, таким, как точность, полнота, f1-мера. В результате анализа была выбрана модель, которая продемонстрировала наилучшие результаты в задачах классификации транспортных средств. Так же была проведена количественная оценка детектора, используемого в дальнейшем, которая подтвердила эффективность выбранной модели. Третий раздел описывает практическую часть работы, в которой были проведены аугментация и дополнение набора данных. После дообучения модели на улучшенных данных была выполнена интеграция классификатора с детектором YOLOv11. Реализован веб-интерфейс, который обеспечивает удобное взаимодействие с системой, позволяя загружать видео, просматривать результаты детекции и классификации в реальном времени, а также анализировать статистические данные. Тестирование системы на реальных данных видеонаблюдения подтвердило эффективность подхода, хотя и выявило необходимость дальнейшей оптимизации для сложных ракурсов и условий освещенности.

**Ключевые слова:** идентификация транспортных средств, машинное обучение, YOLO, компьютерное зрение, аугментация данных

**Цитирование:** Горский М.С. Разработка метода идентификации транспортного средства / М.С. Горский, М.С. Мосева // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 55-69. – DOI:10.25729/ESI.2026.42.2.005.

**Введение.** Современные методы машинного обучения открывают новые возможности для автоматической идентификации транспортных средств. В условиях роста автомобильного парка задача классификации марок и моделей приобретает особую актуальность для систем мониторинга дорожного движения, автоматизации парковок и повышения безопасности.

Целью статьи является описание разработанного авторами метода классификации автомобилей на основе изображений с использованием сверточных нейронных сетей. Создаваемая модель должна выделять ключевые характеристики транспортных средств для их точной идентификации.

Практическая значимость исследования заключается в возможности применения результатов в транспортной логистике, системах видеонаблюдения и других областях, требующих автоматизированного распознавания автомобилей. Реализация проекта будет способствовать совершенствованию управления дорожным движением и снижению зависимости от человеческого фактора.

В статье будет выполнен анализ существующих методов, из которых выбираются наиболее подходящие, проведено сравнение выбранных методов и моделей, определены наиболее успешные, собраны и подготовлены наборы данных для обучения, а также разработан метод идентификации транспортных средств.

**1. Обзор подходов к идентификации транспортных средств.** В сфере дорожного транспорта простого обнаружения транспортных средств недостаточно – необходима их детальная классификация по марке, модели и другим признакам. Эта задача актуальна для таких приложений, как дифференцированная оплата проезда, криминалистика и сбор статистики.

Практическая значимость подчеркивается исследованием [1], где показана связь между типом автомобиля, его скоростью и объемом вредных выбросов. Автоматическая идентификация транспортных средств позволила бы оптимизировать скоростные режимы для разных категорий транспорта, снизив тем самым загрязнение окружающей среды.

Для изучения видов транспортных средств и потоков транспортных средств существуют различные их характеристики. Описать транспортное средство можно с помощью следующих данных: тип кузова, количество осей, назначении, габариты, масса, марка и т.д. [2]. Важным критерием классификации является назначение транспортного средства. В исследованиях [3, 4] служебный транспорт (скорая помощь, полиция) выделяется в отдельный класс для приоритизации проезда и моделирования дорожного движения. Также существуют способы описания транспортных потоков. Исходя из документа [5], можно выделить такие характеристики транспортных потоков, как интенсивность движения, состав движения, пропускная способность, плотность движения.

Задачу классификации транспортных средств можно решить разными способами. Один из способов – использование датчиков для получения информации об автомобиле. В статье [6] авторы используют сканирование автомобиля при помощи датчиков, преобразование получившихся данных в формат изображения, преобразование получившегося изображения и передача этого изображения в сверточную нейронную сеть (рис. 1). В качестве конечной модели использовалась модель EfficientNet.



**Рис. 1.** Преобразование данных LiDAR в изображение для EfficientNet

Решение схожей задачи можно найти в [7]. В ней авторы предлагают подход, который улучшает распознавание объектов в трудных световых условиях. Основной моделью стал REDFormer, который использует в своем алгоритме карты BEV, а также способен настраиваться в зависимости от условий окружающей среды. В статье [8] авторы предложили подход, объединяющий работу модели YOLOv3 и данные, полученные от нейронной сети, использующей данные радара. Для модели, обрабатывающей данные радара, была использована полносвязная сверточная нейронная сеть FCN-8 (рис. 2). В статье [9] для обработки данных радара используется модель, названная RPR. Помимо данных от датчиков, модель принимает на вход данные из сверточной нейронной сети, которая, в свою очередь, принимала входное изображение. Параллельно, на результатах сверточной нейронной сети, работает сеть региональных предложений (RPN). Результаты обеих моделей объединяются и проходят через Fast R-CNN.

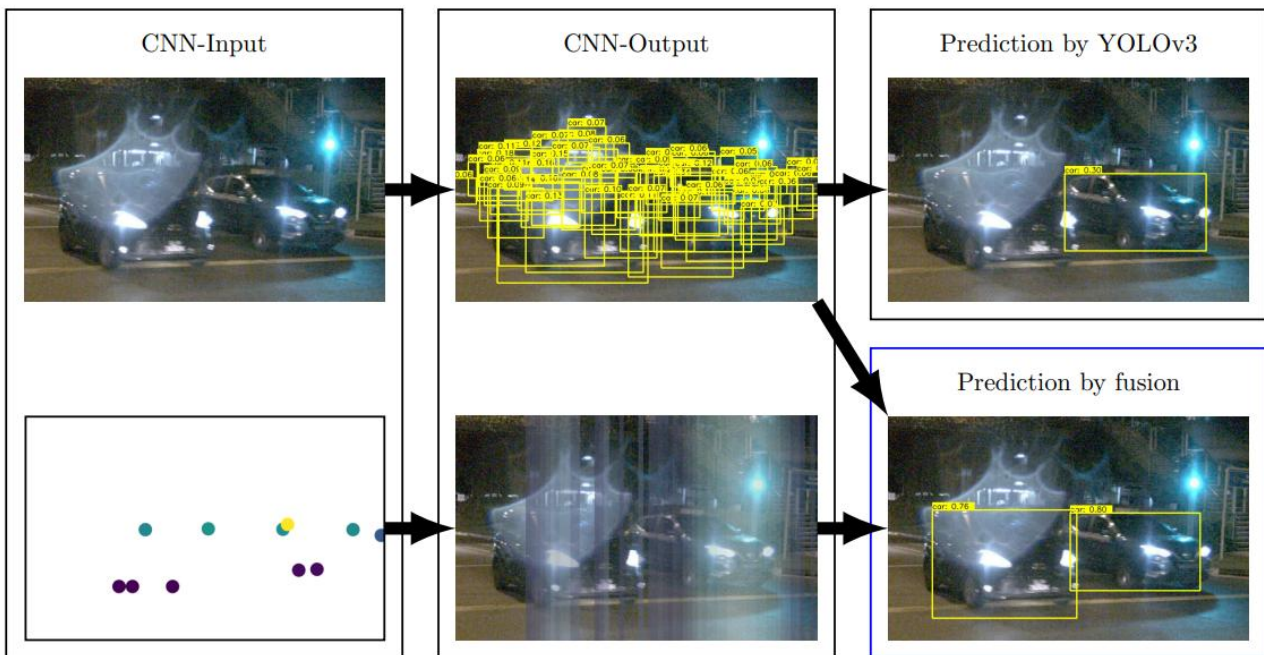


Рис. 2. Принцип работы алгоритма YOdar

Актуальность метода использования датчиков в распознавании автомобилей на изображении подчеркнута в статье [10]. В статье объединяются подходы из других статей, предлагается общий алгоритм слияния моделей, работающих с изображением и с сенсорами. Выполняется сравнение существующих подходов, выявляются как схожие черты, так и различия между ними.

Городские камеры наблюдения требуют не только детектирования, но и классификации транспорта по типу, марке и цвету. В исследовании [11] для классификации иранских автомобилей использовалась связка StrongSORT (YOLOv5, OSNet, ResNet). Для статьи был собран свой датасет иранских автомобилей [12] из 29 классов, лучший результат показала ResNet50. В работе [13] распознавание номеров решается через предварительную классификацию ТС. По итогу лучшей по всем параметрам оказалась TinyYOLOv4.

Исследование [14] посвящено устойчивости классификации к шумам изображения. Предложены фреймворки PMAL для обучения с очисткой от шумов и PMD для компрессии модели, что позволяет сохранить точность при уменьшении вычислительных затрат. В статье [15] проблема идентификации решается внедрением двух модулей в нейронную сеть: LTRA и HFCA. Первый предназначен для оптимизации входных данных, а второй для поиска более точных классификационных признаков (рис. 3)

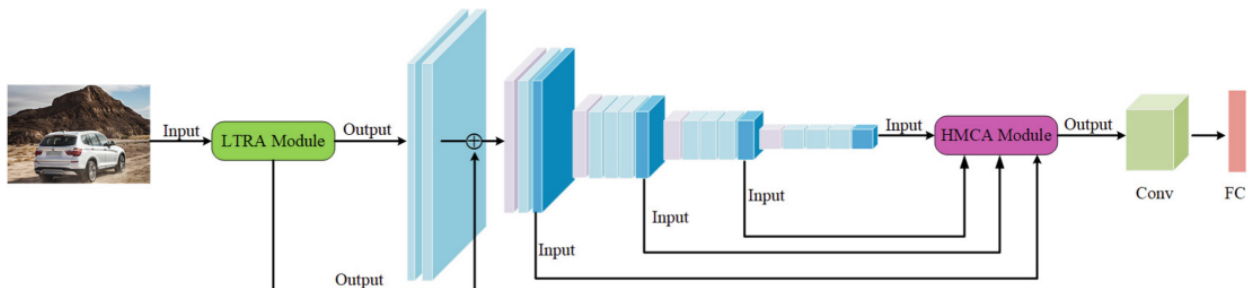


Рис. 3. Пример внедрения модулей LTRA и HFCA

В статье [16] исследованы методы повышения эффективности моделей глубокого обучения в системах ALPR. Метод понижения класса, объединяющий редкие категории в

группу «Другие», повысил точность ViT b16 на 8-12%. Метод выборочного предсказания, отсеивающий недостоверные прогнозы, дал прирост в 8%, а их комбинация – свыше 20%.

В работе [17] предложен классификатор на основе критерия Фишера, используемый совместно с ResNet и VGG. В исследовании [18] для детальной классификации транспортных средств усовершенствован алгоритм WS-DAN методом FAFCC, использующим многоуровневые признаки изображений. В статье [19] сравниваются два подхода: дообучение предобученных сетей и извлечение признаков с последующим использованием SVM. Наилучший результат показал метод дообучения на основе Inception-v3.

В статье [20] для решения задачи детекции была модифицирована модель многообъектного отслеживания FairMOT. Исходная архитектура ResNet34 заменена на CSPDarknet53 для повышения точности в условиях городского трафика. Усовершенствованный алгоритм решает три ключевые задачи: детектирование и повторную идентификацию транспортных средств, расчет их скорости и измерение объема трафика. Для последнего в кадре определяется специальная зона учета, проезд через которую фиксируется, как состоявшееся событие (рис. 4).




Рис. 4. Пример работы алгоритма Fairmot с CSPDarknet53

В статье [21] представлен алгоритм на основе YOLOv5 и DeepSORT, улучшенный модулем Swin Transformer. Для точного определения скорости транспортных средств используется преобразование координат изображения в реальные с помощью ориентиров. Исследование [22] сравнивает популярные архитектуры для распознавания атрибутов автомобиля. Модель RCNN показала наилучшие результаты по точности и F1-мере, тогда как YOLO лидирует по показателю precision. В работе [23] модифицирована архитектура YOLOv5 для повышения эффективности распознавания: добавлен модуль внимания для детекции мелких объектов, заменена агрегирующая сеть на ViFPN и функция потерь на Ciou. Для отслеживания объектов используется сиамская полносвязная сеть (SNN), обеспечивающая устойчивость работы в реальных условиях.

В статье [24] описывается собранный авторами датасет, который объединяет в себе 4 других общедоступных набора данных: CitiFlow, VeRi-776, CompCar и VehicleID. В статье [25] представлено расширение для набора данных Cityscapes, в котором авторы добавили дополнительные атрибуты для каждого класса.

В ранее рассмотренной статье [20] авторы представили свой набор данных THS-10, который включает в себя 4250 изображений и 10 классов. На изображениях представлены японские автомобили марок Honda, Suzuki и Toyota. Авторы статьи [26] представили набор данных с метками, содержащими название марок и моделей автомобилей. Описанный в данной статье набор данных DVMM содержит в себе 43 модели и 495 марок автомобилей в разных ракурсах.

Статья [27] представляет два набора данных для распознавания моделей автомобилей. Первый набор данных представляет собой набор изображений, разделенных метками с типом кузова изображенного транспорта. Другой набор данных представлен изображениями эмблем производителей автомобилей, например, «Chevrolet», «Ford», «Honda» и др.

В статье [28] представлен набор данных из разделенных на кадры видеозаписей с дорожных камер видеонаблюдения. Всего таких кадров в наборе содержится 416314, а всего уникальных автомобилей – 40671. В каждом изображении показана автодорога с несколькими размеченными автомобилями.

**2. Исследование моделей для идентификации транспортных средств.** В результате исследования были выбраны наиболее популярные модели машинного обучения для детекции и классификации транспортных средств. В этом разделе будет выполнена оценка их эффективности по различным метрикам.

Для решения поставленной задачи требуются две модели: одна – для обнаружения автомобилей на изображении, другая – для их классификации по маркам и моделям. Поскольку задача классификации в данном случае сложнее детекции, основной акцент будет сделан на анализе классифицирующих моделей. Для детектирования будет выбрана одна модель для последующего использования.

**2.1. Постановка задачи.** По итогам анализа, проведенного в первом разделе, были выбраны следующие три сверточные модели, решающие задачу классификации: YOLO, ResNet, Inception-v3. Подходы, основанные на архитектуре трансформеров, также используются для решения задач компьютерного зрения, однако, как правило, требуют значительных вычислительных мощностей и памяти для обучения и инференса, что на текущий момент ограничивает их применение в рассматриваемых нами сценариях.

YOLO – это популярная архитектура для детекции и классификации объектов в изображениях и видео, которая была разработана для обеспечения высокой скорости и точности. Основная идея YOLO – способность модели выдавать результат всего за один проход по изображению. Мы возьмем актуальную 11 версию модели, как наиболее новую из всех версий. Также, мы будем использовать два варианта этой модели – YOLOv11 для задачи детекции и YOLO-cls для задачи классификации.

ResNet – это архитектура глубокой нейронной сети, разработанная для решения проблемы затухающего градиента, которая возникает при обучении очень глубоких моделей. Данная архитектура состоит из повторяющихся блоков, каждый из которых включает в себя несколько сверточных слоев и остаточную связь. Исходя из анализа предметной области, мы возьмем вариант с 50-ю слоями, который имеет название ResNet50

Inception-v3 – это модель машинного обучения, которая была разработана для решения задачи классификации изображений и других задач компьютерного зрения. Основная идея модели заключается в параллельном использовании нескольких сверточных слоев, которые позволяют модели извлекать признаки из слоев разных масштабов. Так, модель может

одновременно извлекать признаки из слоев с разным ядром свертки, с разным количеством самих сверточных слоев.

Для выбора классифицирующей модели проведем анализ описанных архитектур и сравним их по различным параметрам. Для детекции будем использовать модель YOLOv11.

Для эксперимента был собран набор данных, содержащий изображения автомобилей разных марок и моделей с различных ракурсов (рис. 5). Набор данных включает в себя 10006 изображений в тренировочной выборке, 4582 изображений в валидационной и 1563 в тестовой. Он включает 23 различных бренда автомобилей, из которых 19 – это легковые автомобили, а 4 – грузовые, автобусы и т.д.



Рис. 5. Пример изображений в наборе данных

Дополнительно был собран небольшой набор данных, состоящий из реальных изображений автомобилей с камер видеонаблюдения. Его отличительной особенностью является реалистичные, но более сложные условия (рис. 6). Набор данных включает в себя не все классы, на которых обучалась модель, но и не содержит классов, на которых модель не обучалась. Представленные изображения были получены при дневном освещении в ясную погоду, съемка осуществлялась с верхней точки, под углом к изображению. Размер изображений не превышал 200 на 200 пикселей. Цель этого набора – исследование того, насколько модель, обученная на описанном наборе данных, сможет ориентироваться на реальных данных.




Рис. 6. Автомобили с камер видеонаблюдения

**2.2. Результаты эксперимента.** В первую очередь было проведено обучение предобученных моделей на описанном наборе данных. Обучение проводилось в 90 эпох, размер пакета был установлен в 16 для YOLO, 32 для ResNet и Inception. Размер входного изображения был установлен в «224 на 224» пикселя, для Inception – в «229 на 229». В качестве оптимизатора использовался стохастический градиентный спуск для YOLO, а для моделей YOLO и Inception был установлен оптимизатор Adam. Все параметры были подобраны экспериментальным путем. Для чистоты поставленного эксперимента у модели YOLO были отключены все параметры, осуществляющие автоматическую аугментацию данных. Результаты можно увидеть в таблице 1. По ней можно сказать, что среди предобученных моделей лучше всего справилась архитектура YOLO. Она имеет наилучшие показатели среди других моделей. Скорость обработки у всех трех моделей остается на высоком уровне.

С учетом достаточно специфичной задачи была сделана гипотеза, что предобученные модели не могут улучшить точность конечной модели, и, более того, могут усложнить процесс обучения. Был проведен ряд экспериментов со случайными начальными весами у моделей. Однако, видимого результата добиться не удалось, все модели показали себя хуже по всем качественным метрикам. В результате наиболее успешной моделью оказалась YOLO-cls, ее точность составила более 82% на тестовой выборке.

Таблица 1. Результаты эксперимента с предобученными моделями

	Точность (топ-1)	Точность (топ-5)	Полнота	Точность (precision)	F1-мера	Скорость предсказания (сек.)
YOLOv11-cls	0.8292	0.9687	0.8292	0.8545	0.8286	0.0226
ResNet50	0.4722	0.7377	0.4722	0.5640	0.4679	0.0220
Inception-v3	0.3225	0.6040	0.3225	0.3225	0.3236	0.0124

Основываясь на том, что модель YOLO показала наилучший результат среди конкурентов, был проведен дополнительный анализ ее эффективности. Для этого обученная модель была протестирована на наборе данных с реальных камер видеонаблюдения. Результаты оказались не такими успешными (рис. 7)




Рис. 7. Матрица ошибок на реальных данных

Как видно из матрицы, модель большинство классов распознала как «Lada 2110-2112», что является важным показателем. Модель смогла справиться с классом грузовых газелей, правильно предсказала классы автобусов ЛиАЗ и НефАЗ. Точность топ-5 составила 14%. Также на рис. 8 показаны конкретные предсказания модели.

На рисунке можно видеть, что в некоторых случаях модель действительно была близка к верному результату. Например, для автомобиля Audi A4 модель правильно определила марку, но ошиблась в модели. Модель хорошо справилась с ford fusion, так как очертания этого автомобиля достаточно индивидуальны.

Кроме того, была выполнена оценка детектора YOLOv11 на валидационной выборке набора данных СОСО. Была выбрана модель «pano» для обеспечения максимальной лёгкости и минимальных вычислительных затрат. Оценка выполнялась по трем классам: «car», «bus», «truck». Точность составила 0.85, а mAP - 0.69.

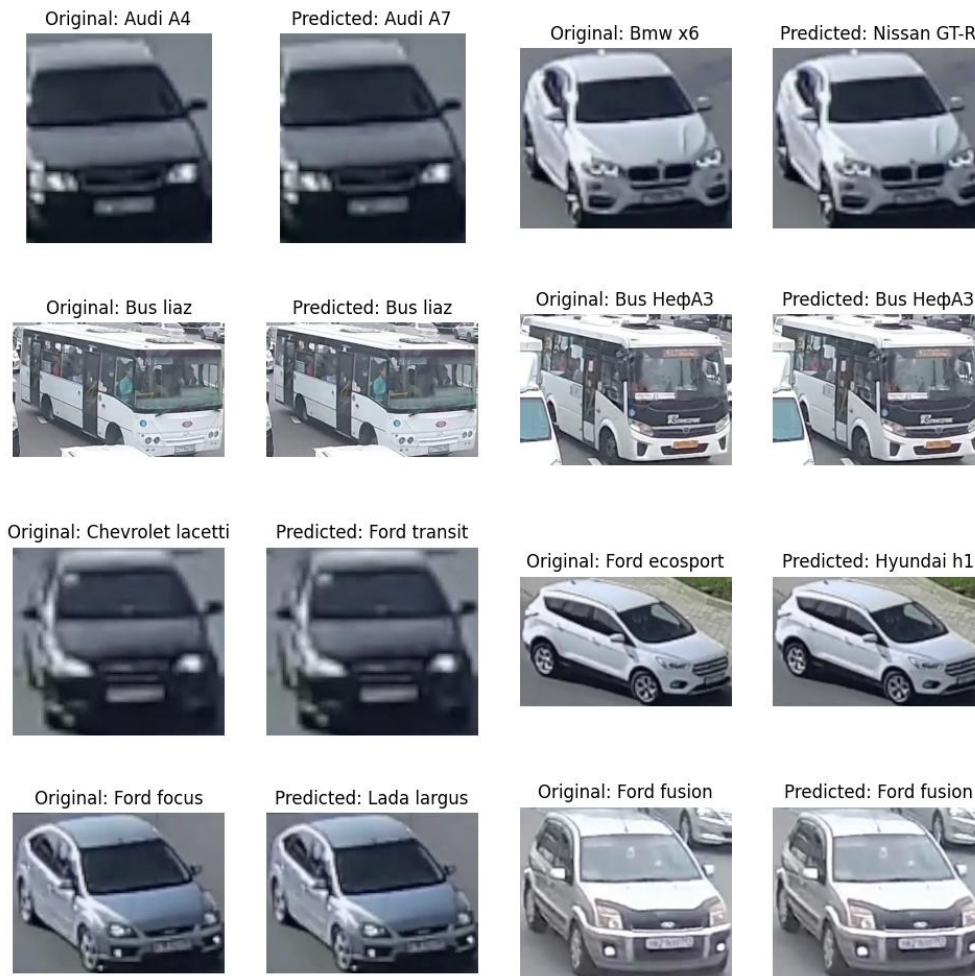


Рис. 8. Предсказания модели на реальных данных

**3. Разработка метода идентификации транспортного средства на изображении.** В этом разделе описана разработка метода идентификации транспортных средств на основе анализа, проведенного в предыдущих главах. Основное внимание уделено разработке оптимизированной модели для точной детекции и классификации автомобилей на изображениях с камер видеонаблюдения.

Для улучшения качества обучения будет использован модифицированный набор данных с применением методов аугментации (вращение, изменение яркости, масштабирование), что особенно актуально в условиях ограниченного объема исходных данных. Дополнительно будет проведен детальный анализ классов транспортных средств для более точной настройки модели.

Завершающий этап – интеграция классифицирующей модели с детектором и комплексная оценка результатов, позволяющая выявить сильные и слабые стороны предложенного метода.

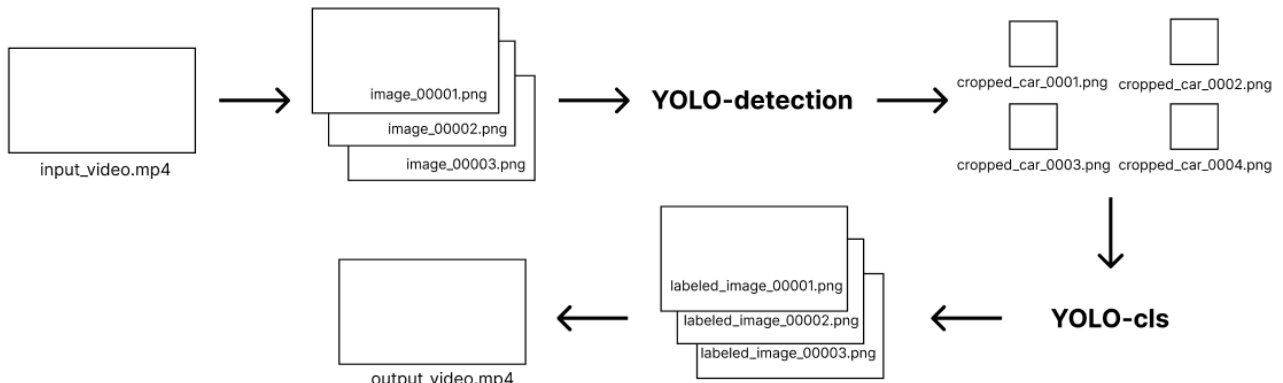
**3.1. Обучение классифицирующей модели.** Исходя из результатов эксперимента, было принято решение об оптимизации набора данных. Изображения были кадрированы по размеру автомобиля. Для некоторых классов было выполнено разделение на несколько разных классов, или объединение в один класс.

Для увеличения количества изображений были применены сдвиг и поворот в качестве методов аугментации для классов, чьих изображений оказалось меньше всего. Далее, для всех изображений было применено зеркальное отражение и наложен гауссовский шум на все получившиеся изображения (рис. 9).



При обучении модель достаточно быстро обучается до ошибки, равной примерно 2 и точности на валидационной выборке 90%. Однако после этого для каждой эпохи модели трудно перешагнуть этот порог.

**3.2. Внедрение детектирующей модели.** Для обработки видео будет применен алгоритм, показанный на рис. 11. Он позволяет на выходе получать обработанное видео с обнаруженными автомобилями и предсказанными их классами.



**Рис. 11.** Алгоритм обработки видеофайла

Из всех распознанных объектов мы будем выбирать только автомобили. Каждый объект, прошедший данную фильтрацию, отправляется на классификацию модели YOLO-cls. На выходе получается видео с предсказанием модели.


Дополнительно было решено создать алгоритм, определяющий цвет автомобиля. Добиться этого удалось при помощи библиотек `opencv` [29] и `numpy` [30]. Основа алгоритма – это перевод изображения в HSV, удобное пространство для выделения цвета (оттенок, насыщенность, яркость). По яркости и насыщенности мы определяем, является ли автомобиль белым, серым или черным, в остальных случаях мы определяем цвет по оттенку – в зависимости от того, в какой диапазон он попадает, мы назначаем цвет. Помимо этого, была использована кластеризация K-средних, которая позволила объединить области пикселей и улучшить результат распознавания. Итоговый результат работы программы можно увидеть на рис. 12.



**Рис. 12.** Результат работы программы

Для удобства работы с алгоритмом был разработан пользовательский интерфейс на базе библиотеки Streamlit [31]. Выбор обусловлен минимальными требованиями к веб-разработке и наличием готовых компонентов для загрузки медиафайлов и визуализации данных. Интерфейс обеспечивает: загрузку видеофайлов, отображение видео с детекцией и классификацией объектов, вывод статистики, включая скорость обработки. Также была добавлена таблица со статистикой, которая содержит все найденные на видео автомобили и их цвет. Это может быть полезно, если мы ищем какое-то определенное транспортное средство. Пример интерфейса представлен на рис. 13.

Обработка завершена!



Обнаруженные объекты

	Класс	Цвет
0	Nissan X-Trail	Белый
1	Toyota Yaris	Белый
2	Kia optima	Белый
5	Nissan Terrano	Белый
6	Citroen c3	Белый
7	Gaz GAZ cargo	Белый
11	Bus НефАЗ	Белый
12	Citroen jumper	Белый
13	Peugeot 408	Белый
14	Kia optima	Серый

Время обработки: 152.17 секунд

Скачать таблицу CSV

Рис. 13. Реализованный интерфейс

**Заключение.** В ходе исследования была успешно разработана система идентификации транспортных средств, основанная на анализе видеопотока. Предложенный метод позволяет определять характеристики транспортных средств за счет комбинации современных моделей детекции и классификации. Ключевым результатом работы является интегрированное решение, объединяющее модель YOLO для детекции транспортных средств на видео и сверточную модель YOLO-cls для их последующей классификации. Выбор моделей был сделан на основе проведенного сравнительного анализа. Аугментация и расширение данных позволили увеличить робастность модели, а разработанный интерфейс обеспечил практическую применимость системы.

Разработанная система может быть внедрена в реальные сценарии, такие, как автоматизированные парковочные комплексы, интеллектуальные системы видеонаблюдения и управления дорожным движением. Это будет способствовать повышению уровня автоматизации и снижению эксплуатационных затрат в указанных областях. В дальнейшем, работа может быть расширена за счет внедрения визуальных трансформеров, что позволит повысить точность идентификации в сложных условиях.

#### Список источников

1. Liu W., Liu J., Yu Q. et al. Optimal speed ranges for different vehicle types for exhaust emission control. Sustainability, 2024, vol. 16, no. 23, p. 10344, DOI: 10.3390/su162310344.
2. Об утверждении Правил применения обязательных требований в отношении отдельных колесных транспортных средств и проведения оценки их соответствия: постановление Правительства Российской Федерации от 12 мая 2022 г. № 855 // Официальный сайт Правительства Российской Федерации. – URL: <http://government.ru/docs/all/140920/> (дата обращения: 25/03/2025).
3. Dong L., Xie X., Zhang L. et al. Satisfaction-based optimal lane change modelling of mixed traffic flow and intersection vehicle guidance control method in an intelligent and connected environment. Sustainability, 2025, vol. 17, no. 3, p. 1077, DOI: 10.3390/su17031077.
4. Aworinde O.H. et al. Development of a prioritized traffic light control system for emergency vehicles. IAES International Journal of Artificial Intelligence (IJ-AI), 2024, vol. 13, no. 4, pp. 4019-4028, DOI: 10.11591/ijai.v13.i4.pp4019-4028.
5. Организация и безопасность дорожного движения на автомагистралях и скоростных автомобильных дорогах: ГОСТ Р 70124–2022: утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии от 26 мая 2022 г. № 376-ст // Официальный сайт ФГУП «Стандартинформ». – URL: <https://docs.cntd.ru/document/1200184428> (дата обращения: 25.03.2025).
6. Ruan G., Hu T., Ding C. et al. Fine-grained vehicle recognition under low light conditions using EfficientNet and image enhancement on LiDAR point cloud data. Scientific Reports, 2025, vol. 15, p. 4691, DOI: 10.1038/s41598-025-89002-3.
7. Cui C., Ma Y., Lu J. et al. Radar enlighten the dark: enhancing low-visibility perception for automated vehicles with camera-radar fusion. arXiv, 2023, DOI: 10.48550/arXiv.2305.17318.

8. Kowol K., Rottmann M., Bracke S. et al. YODar: uncertainty-based sensor fusion for vehicle detection with camera and radar sensors. International Conference on Agents and Artificial Intelligence, 2020. Available at: <https://api.semanticscholar.org/CorpusID:222177987> (accessed: 03/25/2025).
9. Nabati R., Qi H. Radar-camera sensor fusion for joint object detection and distance estimation in autonomous vehicles. arXiv, 2020. Available at: <https://api.semanticscholar.org/CorpusID:221761289> (accessed: 03/25/2025).
10. Shi K., He S., Shi Z. et al. Radar and camera fusion for object detection and tracking: a comprehensive survey. arXiv, 2024. Available at: <https://arxiv.org/abs/2410.19872> (accessed: 03/25/2025).
11. Siahkali F., Alavi S., Masouleh M. SIVD: dataset of Iranian vehicles for real-time multi-camera video tracking and recognition. 2022 7th International Conference on Signal Processing and Intelligent Systems (ICSPIS), 2022, pp. 1-7, DOI: 10.1109/ICSPIS56952.2022.10043932.
12. Maleki P., Ramazani A., Khotanlou H. et al. Iranian vehicle images dataset for object detection algorithm. Journal of Artificial Intelligence and Data Mining, 2024, pp. 127-136, DOI: 10.22044/jadm.2024.13858.2501.
13. Usama M., Anwar H., Anwar A. et al. Vehicle and license plate recognition with novel dataset for toll collection. arXiv, 2022, DOI: 10.48550/arXiv.2202.05631.
14. Liu D. Progressive multi-task anti-noise learning and distilling frameworks for fine-grained vehicle recognition. IEEE Transactions on Intelligent Transportation Systems, 2024, vol. 25, no. 9, pp. 10667–10678, DOI: 10.1109/tits.2024.3420151.
15. Cai W., Zhu W., Cheng B. et al. Dual-rank attention module for fine-grained vehicle model recognition. Pattern Recognition and Computer Vision, 2022, pp. 17-28, DOI: 10.1007/978-3-031-18907-4\_2.
16. Santos E., Lima G.E., Laroca R. et al. Enhancing vehicle identification in challenging conditions through fine-grained classification. Anais da 37ª Conferência de Gráficos, Padrões e Imagens (SIBGRAPI 2024), Manaus, Brazil, 2024, pp. 129-134, DOI: 10.5753/sibgrapi.est.2024.31657.
17. Hayee S., Hussain F., Yousaf M.H. A novel FDLSR-based technique for view-independent vehicle make and model recognition. Sensors, 2023, vol. 23, no. 18, p. 7920, DOI: 10.3390/s23187920.
18. Chen J., Chen Z., Tao S. et al. Fine-grained vehicle classification based on feature augmentation. Journal of Physics: Conference Series, 2022, vol. 2404, p. 012041, DOI: 10.1088/1742-6596/2404/1/012041.
19. Najeeb S.A., Raza R.H., Yusuf A. et al. Fine-grained vehicle classification in urban traffic scenes using deep learning. arXiv, 2021, DOI: 10.48550/arXiv.2111.09403.
20. Cai B., Feng Y., Wang X. et al. Highly accurate deep learning models for estimating traffic characteristics from video data. Applied Sciences, 2024, vol. 14, no. 19, p. 8664, DOI: 10.3390/app14198664.
21. Luo Z., Bi Y., Yang X. et al. Enhanced YOLOv5s + DeepSORT method for highway vehicle speed detection and multi-sensor verification. Frontiers in Physics, 2024, vol. 12, DOI: 10.3389/fphy.2024.1371320.
22. Kanagamalliga S., Kovalan P., Kiran K. et al. Traffic management through cutting-edge vehicle detection, recognition, and tracking innovations. Procedia Computer Science, 2024, vol. 233, pp. 793-800, DOI: 10.1016/j.procs.2024.03.268.
23. Allak A.S.H., Yi J., Al-Sabbagh H.M. et al. Siamese neural networks in unmanned aerial vehicle target tracking process. IEEE Access, 2025, vol. 13, pp. 24309-24322, DOI: 10.1109/ACCESS.2025.3536461.
24. Zheng Z., Ruan T., Wei Y. et al. VehicleNet: learning robust visual representation for vehicle re-identification. IEEE Transactions on Multimedia, 2021, vol. 23, pp. 2683–2693, DOI: 10.1109/tmm.2020.3014488.
25. Metwaly K., Kim A., Branson E. et al. CAR – Cityscapes attributes recognition: a multi-category attributes dataset for autonomous vehicles. arXiv, 2021, DOI: 10.48550/arXiv.2111.08243.
26. Lyu Y., Schioppa I., Cornelis B. et al. Framework for vehicle make and model recognition—a new large-scale dataset and an efficient two-branch–two-stage deep learning architecture. Sensors, 2022, vol. 22, no. 21, p. 8439, DOI: 10.3390/s22218439.
27. Boonsirisumpun N., Okafor E., Surinta O. Vehicle image datasets for image classification. Data in Brief, 2024, vol. 53, p. 110133, DOI: 10.1016/j.dib.2024.110133.
28. Lou Y., Bai Y., Liu J. et al. VERI-Wild: a large dataset and a new method for vehicle re-identification in the wild. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, pp. 3230-3238, DOI: 10.1109/CVPR.2019.00335.
29. OpenCV documentation. Available at: <https://docs.opencv.org/> (accessed: 03/25/2025).
30. NumPy documentation. Available at: <https://numpy.org/doc/stable/> (accessed: 03/25/2025).
31. Streamlit documentation. Available at: <https://docs.streamlit.io/> (accessed: 03/25/2025).

**Горский Максим Сергеевич.** Магистрант кафедры «Математическая кибернетика и информационные технологии», Московский технический университет связи и информатики. ORCID: 0009-0002-6534-1853, [m.s.gorskiy@edu.mtu.ci.ru](mailto:m.s.gorskiy@edu.mtu.ci.ru), 111024, г. Москва, Авиамоторная 8с2.

**Мосева Марина Сергеевна.** Кандидат технических наук, Доцент кафедры Программная инженерия, Московский технический университет связи и информатики. AuthorID: 946893, SPIN: 1313-0436, ORCID: 0000-0002-9778-124X, [m.s.moseva@mtuci.ru](mailto:m.s.moseva@mtuci.ru), 111024, г. Москва, Авиамоторная 8, с.2.

UDC 004.93'12

DOI:10.25729/ESI.2026.42.2.005

## **Vehicle identification method development**

**Maxim S. Gorskiy, Marina S. Moseva**

Moscow technical university of communications and informatics,  
Russia, Moscow, *m.s.gorskiy@edu.mtuci.ru*

**Abstract.** This paper aims to describe the development and training of a model capable of classifying vehicles by make and model based on images, as well as an interface for convenient interaction with the model. The novelty of the work is demonstrated by the use of modern vehicle identification methods for fine-grained classification. The paper is divided into three sections, each covering key aspects of the research. The first section provides a domain analysis, reviewing existing vehicle identification methods, including lidar-based technologies, as well as methods using images and videos. Particular attention is paid to the analysis of modern approaches to classifying vehicles by make, model, and other attributes. This analysis allowed us to identify the strengths and weaknesses of various approaches and justify the choice of deep learning architectures for further research. The second section describes the collected dataset with detailed labeling by make and model used for the study. Three machine learning models are compared using various metrics, such as precision, recall, and f1-score. As a result of the analysis, the model that demonstrated the best results for vehicle classification tasks was selected. A quantitative evaluation of the detector used subsequently was also conducted, confirming the effectiveness of the selected model. The third section describes the practical part of the study, which involved augmenting and expanding the dataset. After further training the model on the improved data, the classifier was integrated with the YOLOv11 detector. A web interface was implemented that provides convenient interaction with the system, allowing users to upload videos, view detection and classification results in real time, and analyze statistical data. Testing the system on real-world video surveillance data confirmed the effectiveness of the approach, although it revealed the need for further optimization for complex camera angles and lighting conditions.

**Keywords:** vehicle identification, machine learning, YOLO, computer vision, data augmentation

### **References**

1. Liu W., Liu J., Yu Q. et al. Optimal speed ranges for different vehicle types for exhaust emission control. *Sustainability*, 2024, vol. 16, no. 23, p. 10344, DOI: 10.3390/su162310344.
2. Decree of the Government of the Russian Federation No. 855 of May 12, 2022. On approval of the rules for applying mandatory requirements for certain wheeled vehicles and conducting their conformity assessment. Available at: <http://government.ru/docs/all/140920/> (accessed: 03/25/2025).
3. Dong L., Xie X., Zhang L. et al. Satisfaction-based optimal lane change modelling of mixed traffic flow and intersection vehicle guidance control method in an intelligent and connected environment. *Sustainability*, 2025, vol. 17, no. 3, p. 1077, DOI: 10.3390/su17031077.
4. Aworinde O.H. et al. Development of a prioritized traffic light control system for emergency vehicles. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 2024, vol. 13, no. 4, pp. 4019-4028, DOI: 10.11591/ijai.v13.i4.pp4019-4028.
5. Organizaciya i bezopasnost' dorozhnogo dvizheniya na avtomagistralyah i skorostnyh avtomobil'nyh dorogah [Organization and Road Safety on Highways and Express Roads]: GOST R 70124–2022: approved and enacted by the Order of the Federal Agency on Technical Regulating and Metrology dated May 26, 2022 no. 376-st // Oficial'nyj sait FGUP «Standartinform» [Official website of the FGUP "Standartinform"]. (accessed: 03/25/2024).
6. Ruan G., Hu T., Ding C. et al. Fine-grained vehicle recognition under low light conditions using EfficientNet and image enhancement on LiDAR point cloud data. *Scientific Reports*, 2025, vol. 15, p. 4691, DOI: 10.1038/s41598-025-89002-3.
7. Cui C., Ma Y., Lu J. et al. Radar enlighten the dark: enhancing low-visibility perception for automated vehicles with camera-radar fusion. *arXiv*, 2023, DOI: 10.48550/arXiv.2305.17318.
8. Kowol K., Rottmann M., Bracke S. et al. YODar: uncertainty-based sensor fusion for vehicle detection with camera and radar sensors. *International Conference on Agents and Artificial Intelligence*, 2020. Available at: <https://api.semanticscholar.org/CorpusID:222177987> (accessed: 03/25/2025).
9. Nabati R., Qi H. Radar-camera sensor fusion for joint object detection and distance estimation in autonomous vehicles. *arXiv*, 2020. Available at: <https://api.semanticscholar.org/CorpusID:221761289> (accessed: 03/25/2025).
10. Shi K., He S., Shi Z. et al. Radar and camera fusion for object detection and tracking: a comprehensive survey. *arXiv*, 2024. Available at: <https://arxiv.org/abs/2410.19872> (accessed: 03/25/2025).

11. Siahkali F., Alavi S., Masouleh M. SIVD: dataset of Iranian vehicles for real-time multi-camera video tracking and recognition. 2022 7th International Conference on Signal Processing and Intelligent Systems (ICSPIS), 2022, pp. 1-7, DOI: 10.1109/ICSPIS56952.2022.10043932.
12. Maleki P., Ramazani A., Khotanlou H. et al. Iranian vehicle images dataset for object detection algorithm. Journal of Artificial Intelligence and Data Mining, 2024, pp. 127-136, DOI: 10.22044/jadm.2024.13858.2501.
13. Usama M., Anwar H., Anwar A. et al. Vehicle and license plate recognition with novel dataset for toll collection. arXiv, 2022, DOI: 10.48550/arXiv.2202.05631.
14. Liu D. Progressive multi-task anti-noise learning and distilling frameworks for fine-grained vehicle recognition. IEEE Transactions on Intelligent Transportation Systems, 2024, vol. 25, no. 9, pp. 10667–10678, DOI: 10.1109/tits.2024.3420151.
15. Cai W., Zhu W., Cheng B. et al. Dual-rank attention module for fine-grained vehicle model recognition. Pattern Recognition and Computer Vision, 2022, pp. 17-28, DOI: 10.1007/978-3-031-18907-4\_2.
16. Santos E., Lima G.E., Laroca R. et al. Enhancing vehicle identification in challenging conditions through fine-grained classification. Anais da 37<sup>a</sup> Conferência de Gráficos, Padrões e Imagens (SIBGRAPI 2024), Manaus, Brazil, 2024, pp. 129-134, DOI: 10.5753/sibgrapi.est.2024.31657.
17. Hayee S., Hussain F., Yousaf M.H. A novel FDLNR-based technique for view-independent vehicle make and model recognition. Sensors, 2023, vol. 23, no. 18, p. 7920, DOI: 10.3390/s23187920.
18. Chen J., Chen Z., Tao S. et al. Fine-grained vehicle classification based on feature augmentation. Journal of Physics: Conference Series, 2022, vol. 2404, p. 012041, DOI: 10.1088/1742-6596/2404/1/012041.
19. Najeeb S.A., Raza R.H., Yusuf A. et al. Fine-grained vehicle classification in urban traffic scenes using deep learning. arXiv, 2021, DOI: 10.48550/arXiv.2111.09403.
20. Cai B., Feng Y., Wang X. et al. Highly accurate deep learning models for estimating traffic characteristics from video data. Applied Sciences, 2024, vol. 14, no. 19, p. 8664, DOI: 10.3390/app14198664.
21. Luo Z., Bi Y., Yang X. et al. Enhanced YOLOv5s + DeepSORT method for highway vehicle speed detection and multi-sensor verification. Frontiers in Physics, 2024, vol. 12, DOI: 10.3389/fphy.2024.1371320.
22. Kanagamalliga S., Kovalan P., Kiran K. et al. Traffic management through cutting-edge vehicle detection, recognition, and tracking innovations. Procedia Computer Science, 2024, vol. 233, pp. 793-800, DOI: 10.1016/j.procs.2024.03.268.
23. Allak A.S.H., Yi J., Al-Sabbagh H.M. et al. Siamese neural networks in unmanned aerial vehicle target tracking process. IEEE Access, 2025, vol. 13, pp. 24309-24322, DOI: 10.1109/ACCESS.2025.3536461.
24. Zheng Z., Ruan T., Wei Y. et al. VehicleNet: learning robust visual representation for vehicle re-identification. IEEE Transactions on Multimedia, 2021, vol. 23, pp. 2683–2693, DOI: 10.1109/tmm.2020.3014488.
25. Metwaly K., Kim A., Branson E. et al. CAR – Cityscapes attributes recognition: a multi-category attributes dataset for autonomous vehicles. arXiv, 2021, DOI: 10.48550/arXiv.2111.08243.
26. Lyu Y., Schiopu I., Cornelis B. et al. Framework for vehicle make and model recognition—a new large-scale dataset and an efficient two-branch–two-stage deep learning architecture. Sensors, 2022, vol. 22, no. 21, p. 8439, DOI: 10.3390/s22218439.
27. Boonsirirumpun N., Okafor E., Surinta O. Vehicle image datasets for image classification. Data in Brief, 2024, vol. 53, p. 110133, DOI: 10.1016/j.dib.2024.110133.
28. Lou Y., Bai Y., Liu J. et al. VERI-Wild: a large dataset and a new method for vehicle re-identification in the wild. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, pp. 3230-3238, DOI: 10.1109/CVPR.2019.00335.
29. OpenCV documentation. Available at: <https://docs.opencv.org/> (accessed: 03/25/2025).
30. NumPy documentation. Available at: <https://numpy.org/doc/stable/> (accessed: 03/25/2025).
31. Streamlit documentation. Available at: <https://docs.streamlit.io/> (accessed: 03/25/2025).

**Gorskiy Maxim Sergeevich.** Master's Student, Department of «Mathematical Cybernetics and Information Technology», Moscow Technical University of Communications and Informatics. ORCID: 0009-0002-6534-1853, m.s.gorskiy@edu.mtuci.ru, 111024, Moscow, Aviamotornaya 8s2.

**Moseva Marina Sergeevna.** Candidate of Sciences (Engineering), Associate Professor of the Software Engineering Department, Moscow Technical University of Communications and Informatics. AuthorID: 946893, SPIN: 1313-0436, ORCID: 0000-0002-9778-124X, m.s.moseva@mtuci.ru, 111024, Moscow, Aviamotornaya 8s2.

Статья поступила в редакцию 06.11.2025; одобрена после рецензирования 26.12.2025; принята к публикации 12.05.2026.

The article was submitted 11/06/2025; approved after reviewing 12/26/2025; accepted for publication 05/12/2026.

## Математическое моделирование и его применение в научных исследованиях

УДК 519.7

DOI:10.25729/ESI.2026.42.2.006

### Оптимизация гибкой организации большого числа работ в задаче управления командной реализацией проектов

Колесникова Светлана Ивановна, Фоменкова Анастасия Алексеевна,  
Поляков Виктор Валерьевич

Санкт-Петербургский государственный университет аэрокосмического приборостроения,  
Россия, Санкт-Петербург, *skolesnikova@yandex.ru*

**Аннотация.** Рассматривается задача управления назначением работ при большом динамически пополняемом их объеме. Несмотря на имеющиеся инструменты автоматизации разработки больших программ (AGILE-продукты, продукты Waterfall и другие), проблема оперативного и корректного вмешательства в процесс их производства при изменяющихся внешних и внутренних условиях стоит достаточно остро в силу возникающих отрицательных последствий (задержки выполнения проекта во времени, выход за рамки бюджета, незавершенность проектов из-за неудовлетворительного качества). Наиболее острая проблема в больших проектах – «оптимальное» назначение работ в соответствии с зафиксированными текущими компетенциями сотрудников, при этом отмечено в ряде исследований (опросы от Scrum Inc.), что связь между внедрением наиболее популярных продуктов Agile и ростом эффективности разработки программ носит противоречивый характер. По этой причине разработка усовершенствований имеющихся инструментов актуальна в задачах управления производством крупных программных проектов, где особенно остро стоят проблемы взаимосвязанных ресурсных ограничений: временных, стоимостных, вычислительных. Цель исследования – представление модели и реализующего ее алгоритма оптимизации процесса назначения работ с ориентацией на большие данные (с позиции субъекта-разработчика), приводящего к экспоненциальному выигрышу во времени и ресурсах при сравнении вариантов в форме альтернатив (работа, работник). Особенностью модели является оптимальный алгоритм ранжирования большого числа вариантов, выполняемый в режиме реального времени, и приводящий практически к не улучшаемому корректному решению в задаче упорядочивания динамически пополняемого множества альтернатив, что соответствует важнейшему принципу разработки «здесь и сейчас», заключающемуся в немедленной реакции на изменяющиеся условия и требования заказчика. Выигрыш достигается за счет немеханического совмещения применений трех методов: классического метода парных сравнений, его модификации, корректной в смысле аксиомы К. Эрроу о независимости выбора (предпочтений) от ранее достигнутых ранжирований, и выбранного алгоритма сортировки числовой последовательности. Приведены примеры численного моделирования, подтверждающие заявленные характеристики алгоритма выбора оптимальной альтернативы (работа, работник), в условиях больших данных.

**Ключевые слова:** плохо формализуемый объект, алгоритмы принятия решений, управление проектом, динамическая модель назначений работ, большие данные, корректная модификация метода парных сравнений больших данных, коллектив алгоритмов оценивания, цепь Маркова

**Цитирование:** Колесникова С.И. Оптимизация гибкой организации большого числа работ в задаче управления командной реализацией проектов / С.И. Колесникова, А.А. Фоменкова, В.В. Поляков // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 70-86. – DOI:10.25729/ESI.2026.42.2.006.

**Введение.** Программный проект представляет собой продукт временной деятельности предприятия, направленной на создание уникального программного решения, удовлетворяющего потребности заказчика (человека, предприятия и др.) требуемого качества (например, [1-12]). В сфере разработки программного обеспечения на всех этапах типовых процессов (планирование, сбор требований с последующей спецификацией проекта, проектирование программной системы, реализация, тестирование, развертывание, поддержка) требуются действия (альтернативы), обоснование которых осуществляется на множестве

критериев. К наиболее распространенным технологиям управления проектами относят продукты Waterfall (каскадная методология), Agile (гибкая методология с рядом разработанных фреймворков (Scrum, Extreme Programming, Kanban и др.)), системно-инженерный подход [6], гибридный [5] и другие [7-9].

**1. Краткий обзор литературы с анализом эффективности методологий управления проектами.** Обзор современной литературы (например, [6-15]) с анализом текущего положения в методологиях управления проектами зачастую включает в себя доступные в открытой печати исследования с некоторой статистической информацией и выводами, склоняющими читателя к определенной точке зрения для достижения субъективных целей (с ненулевой вероятностью могущей быть опротестованной оппонентами), но факт множественности методологий свидетельствует о несовершенстве предлагаемых решений и отсутствию единых «шаблонов» в процессе управления проектами.

Следует также отметить возрастающее число сторонников движения «NoProjects», – противников использования инструментов для управления проектами в качестве инструмента для разработки программного обеспечения [11, 13] (тип проектов, который имеет самый высокий процент неудач). Так, согласно статистическим данным The Standish Group (The Chaos Report) в течение только одного года 31% исследуемых проектов завершились успешно, 50% оказались проблемными, а 19% – провальными. Аргументом для принятия такой парадигмы является следующая позиция: программа – это продукт с полным жизненным циклом создания, развития и поддержки, а не разовая акция, в отличие от проектов, фокус на которых сосредоточен только на этапе создания.

К основным причинам неуспешности проектов (в том числе согласно анализу из [8-13]) относят следующие:

- перерасход трудозатрат и/или нарушение сроков (89%);
- недостаточная квалификация топ-менеджера в каскадных проектах; что примечательно: в тех Agile-проектах, где во главе разработки стоит высококвалифицированный руководитель, провалы случаются так же часто, как и успехи;
- использование специализированных инструментов для реализации проектов при решении технических проектов (задач);
- разработка крупных проектов (табл. 1), при этом категоризация «крупный, средний, малый» рассматривается с точки зрения субъекта-разработчика;
- техническая некомпетентность (в целом: руководителя, исполнителей).

Согласно тем же отчетам [11], появляющимся дважды в год с 1994 г., у больших Agile-проектов значительно больше шансов на успех, чем у Waterfall-проектов (табл. 1), а вероятность провала Waterfall-проектов почти в 2 раза выше для средних и больших проектов.

**Таблица 1.** Результаты исследования Standish Group

	<b>Agile-продукты</b>	<b>Каскадные продукты</b>
<b>Большие проекты</b>	19%	8%
<b>Средние проекты</b>	31%	19%
<b>Малые проекты</b>	59%	45%

Таким образом, из текущего анализа [12-16] следует, что связь между внедрением продуктов Agile и ростом эффективности разработки программ имеет противоречивый характер (см., например, исследования [15]. Согласно опросам от Scrum Inc., 47 % Agile-инициатив сопровождаются задержками, выходят за рамки бюджета или приводят к недовольству клиентов.

Важно также отметить, что одной из важных проблем, влияющих на итоговые показатели реализации больших проектов [6-15], отмечена задача оптимального динамического распределения текущих работ между исполнителями, хаотичность и число которых возрастает с возникновением практически неизбежных форс-мажорных ситуаций (изменений экзо- и эндогенных факторов – требований заказчика, условий рынка, финансовых условий, состава работников и пр.).

Уместно также отметить, что, согласно анализу решений задач стратегического управления, проводимому международной консалтинговой компанией McKinsey, фирмы, преуспевающие в *персонализации* назначения работ, получают на 40% больше дохода по сравнению со средним показателем, что свидетельствует о важности корректности задачи о назначениях и перспективе конкурентного преимущества при ее реализации в условиях динамически изменяющихся наборах альтернатив большого размера.

К примерам IT-проектов с большим количеством задач и ограниченным временем на принятие решений для их распределения среди сотрудников относятся следующие:

- разработка программного обеспечения для банков: проекты по созданию или обновлению банковских систем (например, интернет-банкинга) требуют быстрого назначения разработчиков, тестировщиков и аналитиков, чтобы соответствовать строгим срокам и требованиям регуляторов;
- масштабные проекты по обслуживанию миграции данных: при миграции данных из одной системы в другую (например, при переходе на облачные решения) необходимо быстро формировать команды специалистов для анализа, очистки и переноса данных, чтобы минимизировать время простоя;
- создание мобильных приложений: в проектах по разработке мобильных приложений для крупных клиентов (например, для e-commerce) часто возникает необходимость в быстром назначении UX/UI дизайнеров, разработчиков и тестировщиков, чтобы уложиться в сроки запуска;
- внедрение ERP-систем: проекты по внедрению систем управления предприятием (например, SAP или Oracle) требуют оперативного назначения консультантов и разработчиков для настройки системы под конкретные бизнес-процессы клиента;
- проекты по кибербезопасности: в случае обнаружения уязвимостей или инцидентов в безопасности требуется быстро собрать команду специалистов для анализа ситуации и разработки мер по устранению угроз;
- разработка игр: в индустрии видеоигр часто возникают ситуации, когда необходимо быстро назначить художников, программистов и тестировщиков для выполнения задач в рамках сжатых сроков разработки и выхода на рынок;
- проекты по интеграции API: в рамках проектов по интеграции различных систем через API необходимо быстро формировать команды разработчиков и интеграторов для обеспечения совместимости и функциональности и многие другие.

Так, к примеру, в 2020 году компании Apple и Google быстро объединились для разработки технологии отслеживания контактов, чтобы помочь в борьбе с пандемией COVID-19. Это потребовало быстрой работы команд разработчиков, дизайнеров и специалистов по безопасности для создания и внедрения приложения в кратчайшие сроки.

Из анализа литературы также следует, что используемые подходы относительно процессов обработки больших данных считаются устаревшими [14-16], и ни один из инструментов работы с проектами не обладает свойством «общепринятости» ни для анализа больших данных (исключая специальные проблемно-ориентированные фреймворки), ни для оперативного распределения большого числа мелких и крупных работ в режиме реального

времени (в [14] проведен анализ 208-и последних публикаций по гибким технологиям). Таким образом, проблема big data открытая [16], несмотря на весь спектр инструментов.

**2. Формализация постановки задачи о назначениях.** Настоящая работа имеет целью представить корректный (безошибочный на обучающих выборках) инструмент автоматизации процесса назначений работников (в рамках задачи управления данными [17]) на основе оригинального алгоритма быстрого ранжирования работников (согласно имеющимся компетенциям) относительно возникшей работы в форс-мажорных обстоятельствах. Основой является модель последовательно выполняющихся работ и их логических взаимосвязей, заданных в виде простой однородной цепи Маркова. Особенностью процесса являются большие размерности наборов альтернатив (работа, работник).

Пусть имеется набор (смотреть, например, работы [18-20]):

$$M = \langle \mathbf{W}, \mathbf{P} \rangle,$$

где  $\mathbf{W} = \{w_i | i = \overline{1, N_w}\}$  – множество работ,  $w_{N_w}$  – фиктивная работа, необходимая для обозначения завершения проекта;  $\mathbf{P} = \|p_{jk} | j = \overline{1, N_w}, i = \overline{1, N_w}\|_{N_w \times N_w}$  – матрица переходов между работами, где  $p_{jk}$  – вероятность перехода от работы  $j$  к работе  $k$ ;  $N_w$  – количество работ.

Для матрицы  $\mathbf{P}$  соблюдаются естественные условия:

- $p_{jk} = 0$ , если переход от работы  $j$  к работе  $k$  невозможен;
- $\sum_k p_{jk} = 1$ , условие нормировки;
- $p_{jk} = 1$ , при  $j = k = N_w$ , для обозначения завершения проекта.

Априорное распределение вероятностей работ задано в виде множества:

$$\mathbf{Q}_0 = \{q_{0_i} | i = \overline{1, N_w}\},$$

где  $q_{0_i}$  – вероятность работы  $w_i$ .

Будем полагать для определенности заданными:

- предельное (директивное) время выполнения работ в часах, заданное в виде матрицы:

$$\mathbf{TD} = \|td_i\|_{1 \times N_w},$$

где  $td_i$  – предельное (директивное) время выполнения работы  $w_i$ ,  $td_{N_w} = 0$  для фиктивной работы  $w_{N_w}$ ;

- предельный бюджет на выполнение каждой из работ, заданный в виде множества:

$$\mathbf{CD} = \{cd_i | i = \overline{1, N_w}\},$$

где  $cd_i$  – предельный бюджет на выполнение работы  $w_i$ , причем  $cd_{N_w} = 0$  для фиктивной работы  $w_{N_w}$ ;

- штат работников разных категорий и квалификации:

$$\mathbf{E} = \{e_j | j = \overline{1, N_e}\},$$

где  $e_j$  – работник;  $N_e$  – общее количество работников;

- квалификационные группы работников и их структура:

$$\mathbf{G} = \{g_k | k = \overline{1, N_g}\},$$

где  $g_k$  – группа работников;  $N_g$  – общее количество групп; матрица принадлежности работников:  $\mathbf{L} = \|l_{kj}\|_{N_g \times N_e}$ , где  $l_{kj} = \begin{cases} 1 \\ 0 \end{cases}$  – признак принадлежности к группе  $g_k$  работника  $e_j$  (1 – принадлежит; 0 – нет);

- сумма заработной платы в час, заданная в виде вектора:

$$\mathbf{S} = \{s_k | k = \overline{1, N_g}\},$$

где  $s_k$  – заработная плата в час работника группы  $g_k$ ;

- матрица связи между группами работников и работами (предполагается, что квалификация групп позволяет выполнить определенный вид работы):

$$\mathbf{H} = \|h_{ik}\|_{N_w \times N_g},$$

где  $h_{ik} = \begin{cases} 1 \\ 0 \end{cases}$  – признак участия в работе  $w_i$  группы работников  $g_k$  (1 – участвует; 0 – нет), причем  $h_{N_w N_g} = 0$  для фиктивной работы  $w_{N_w}$ ;

- оценки показателя длительности выполнения работ отдельным работником:

$$\mathbf{TP} = \|tp_{ij}\|_{N_w \times N_e},$$

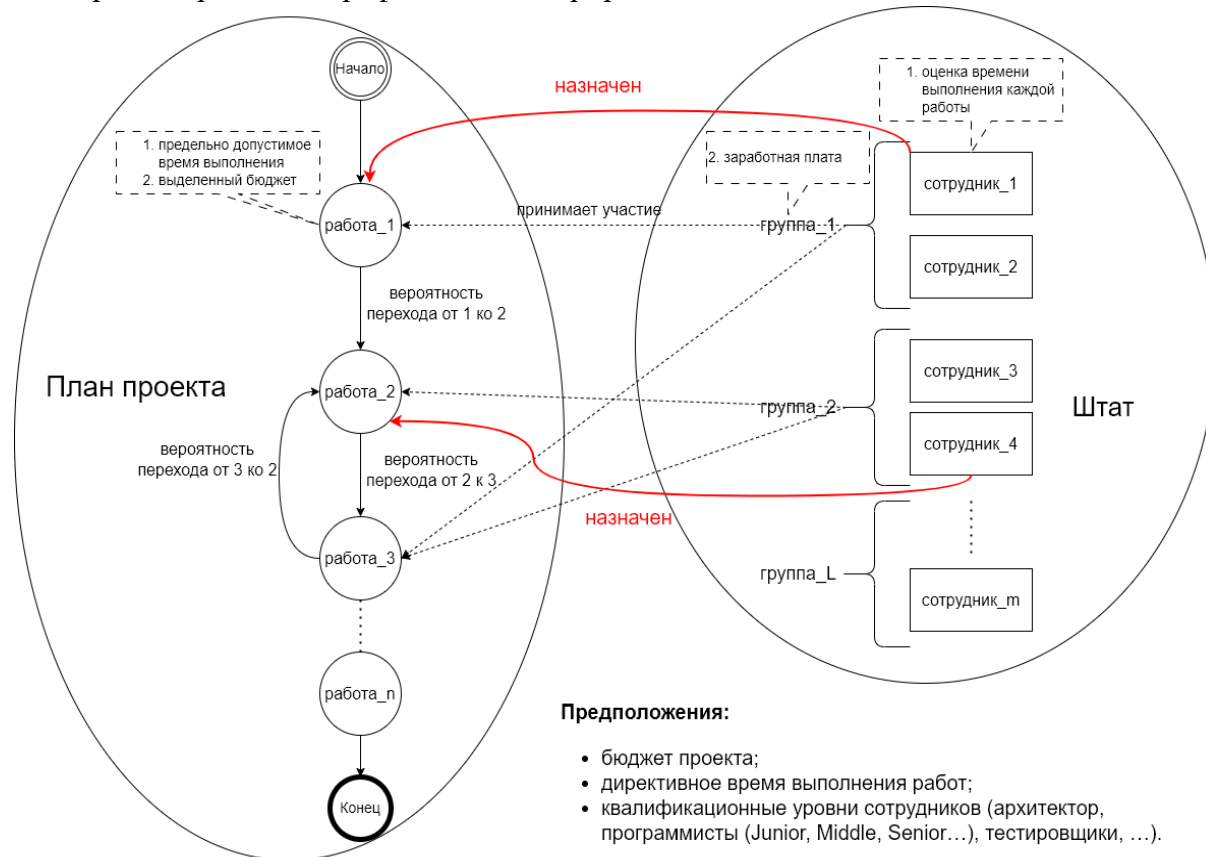
где  $tp_{ij}$  – коэффициент длительности выполнения работы  $w_i$  работником  $e_j$ .

Под коэффициентом длительности выполнения работы понимается значение, на которое умножается предельное (директивное) время выполнения работы из **TD**, для последующего вычисления оценки времени.

Для матрицы **TP** соблюдаются следующие условия:


- $tp_{ij} = 0$ , если работник  $e_j$  не может участвовать в работе  $w_i$ ;
- $0 < tp_{ij} \leq 1$ , если работник  $e_j$  укладывается в директивные сроки работы  $w_i$  при выполнении работы без участия других работников;
- $tp_{ij} > 1$ , если работник  $e_j$  не укладывается в директивные сроки работы  $w_i$  при выполнении работы без участия других работников.

На рис. 1 приведена графическая интерпретация постановки задачи, изложенной выше.



**Рис. 1.** Графическая интерпретация постановки задачи управления процессом командной реализации программного проекта

Пусть для каждого работника имеется «цифровая карточка» (рис. 2), содержащая сведения статистического характера, естественно обновляемые в процессе деятельности каждого работника.

Иванов	Средние числовые показатели деятельности	
Иван 	- отклонение относительно планирования спринта	46%
	- заполняемость спринта задачами	87%
	- автономность в целом:	42%
	○ степень независимости участника группы	85%
	○ уровень в системе менторства	73%
	○ степень невозвратности задач после кода-ревью/тестирования	91%
Общие статистические данные и прогноз надежности	- число завершенных задач	305
	- количество закрытых целевых установок	14
	- число спринтов с незакрытыми целями	3
	Вероятность, что задача не будет закрыта	20%

**Рис. 2.** Пример статистических данных в цифровой карточке работника-программиста при использовании систем управления проектами для командной работы

Ставится задача корректного ранжирования пар (работа, работник) по критериям, состав и важность которых устанавливается экспертом в зависимости от текущих особенностей проекта (длительность выполнения работы, финансовые затраты, квалификация работника и пр.) с целью совершенствования результативности решения частных задач, что будет способствовать не только повышению оперативности в принятии решений, но и корректности выбора, а, следовательно, и качества выполняемой работы.

*Замечание 1.* Обработка больших наборов исходных данных в режиме реального времени по нескольким критериям (показателям) – одна из основных задач в проблеме выбора. В этой связи решение задачи автоматизации процесса персонифицированных назначений в виде системы (работа, работник), или ранжирование большого числа альтернатив по предпочтительности для принятия решения о текущем выборе работника пары для фиксированного вида работы, может быть неким оптимизатором в любой известной методологии управления проектами [12-16].

В качестве альтернатив в задаче выступают всевозможные варианты назначений работников на работу:

$$A = \left\{ (w_i, e_j)_m \mid i = \overline{1, N_w}, j = \overline{1, N_e}, m = \overline{1, N_A} \right\},$$

где  $(w_i, e_j)_m$  –  $m$ -я альтернатива, реализующая вариант назначения работника  $e_j$  на работу  $w_i$ ;  $N_A$  – количество альтернатив (возможных вариантов назначений).

Относительно альтернатив требуется соблюдение условий, обеспечивающих корректность их дальнейшего анализа (существование и выполнимость работ за конечное время, актуального исполнителя с определенными параметрами).

В качестве показателей оценивания выполнения задач работником выберем наиболее распространенные и используемые в реальной работе:

- автономность выполнения заданий (C1) с минимальным вовлечением других участников; например, степень  $x(n)$  безвозвратности задач после проверки со значениями в зависимости от количества  $n$  отметок рецензента в тайм-трекере:  $x(n), x \in (100\%, 80\%, 50\%, 0\%, 0\%, \dots 0\%), n \in [1, \infty]$ , как показатель с числовой интерпретацией данной характеристики;
- полнота итерации (C2);
- относительная оценка времени выполнения работы (C3), указывающая на степень выполнения задачи работником в рамках запланированного времени:

$$T_{pc} = \sum_{i=1..k} t_{pci}; T_{fc} = \sum_{i=1..k} t_{fci}, D_c = \frac{T_{pc} - T_{fc}}{T_{pc}} \cdot 100\%,$$

где  $k$  – количество выполненных задач,  $T_{pc}$  – общее плановое время выполненных за итерацию задач,  $t_{pci}$  – плановое время на  $i$ -ю выполненную задачу,  $T_{fc}$  – общее фактическое время выполненных за итерацию задач,  $t_{fci}$  – фактическое время на  $i$ -ю задачу,  $D_c$  – отклонение от оценки по выполненным за итерацию задачам;

- денежные затраты (С5), обусловленные парой (работа, работник) и другие характеристики, обусловленные конкретным проектом.

**3. Подходы к решению проблемы.** К решению одной из самых востребованных задач коллективного производства продукта – организации процедуры назначения работ (или распределения пар (работа, работник)), имеющей много интерпретаций, разработаны несколько подходов (напр., обзоры в [20-31]) – аналитических и численных, на основе которых созданы многочисленные алгоритмы (что свидетельствует о сложности проблемы и об отсутствии единого подхода к ее решению, табл. 2):

- алгоритмы динамического программирования, сводящиеся к последовательности задач линейного программирования и восходящие к задаче Беллмана о кратчайшей по времени последовательности обработки деталей на нескольких станках;
- эвристические алгоритмы (экспертные решения и алгоритмы согласования частных решений, поиск оптимума на парето-множествах типа «затраты-эффект», генетические и нейросетевые алгоритмы, аукционы и др.);
- методы многокритериального принятия решений, основанные на правилах, и алгоритмы принятия решений в условиях неопределенности;
- вероятностно-статистические методы и связанные со статистической обработкой имитационные модели, близкие по реализации к моделям массового обслуживания, и другие.

**Таблица 2.** Краткие характеристики подходов к решению задачи о назначениях

Подходы, методы, алгоритмы	Проблемы	Отношение к неопределенности и адаптация к изменениям в процессах разработки
Доказательные аналитические методы (смотреть, например, обзоры в [20]).	Ограничение вычислительных ресурсов при больших наборах работ; требование определенных стационарных условий.	Отсутствие адаптивности относительно форс-мажорных обстоятельств, на возможные накладки в системе (работа, работник), почти неизбежно возникающие в процессе реализации проекта при параллельной разработке
Модели управления разработкой программных систем [5-17].	В условиях параллельного назначения работ на практике зачастую хаос и трудно поддающийся управлению процесс. Отсутствие автоматизации обработки больших наборов (работа, работник) в режиме реального времени. Сложность выбора модели (среди более полусотни систем управления командными проектами)	Использование принципа итеративности затруднено разными характеристиками смежных работ (приоритет, длительность, затраты) при возврате задачи на предыдущий этап.

Эвристические, вероятностно-статистические методы, имитационные модели [18, 20, 29].	Нерешенные проблемы больших данных, неприменимость статистики в хаотических режимах.	Трудоемкость процесса перенастройки параметров при изменении исходных данных.
Модели многокритериального принятия решений [24-28].	Ограничения на размер исходных данных и определенные ресурсные и временные препятствия	Негибкость к изменениям: возможны нарушения транзитивности предпочтений при увеличении множества выбора.

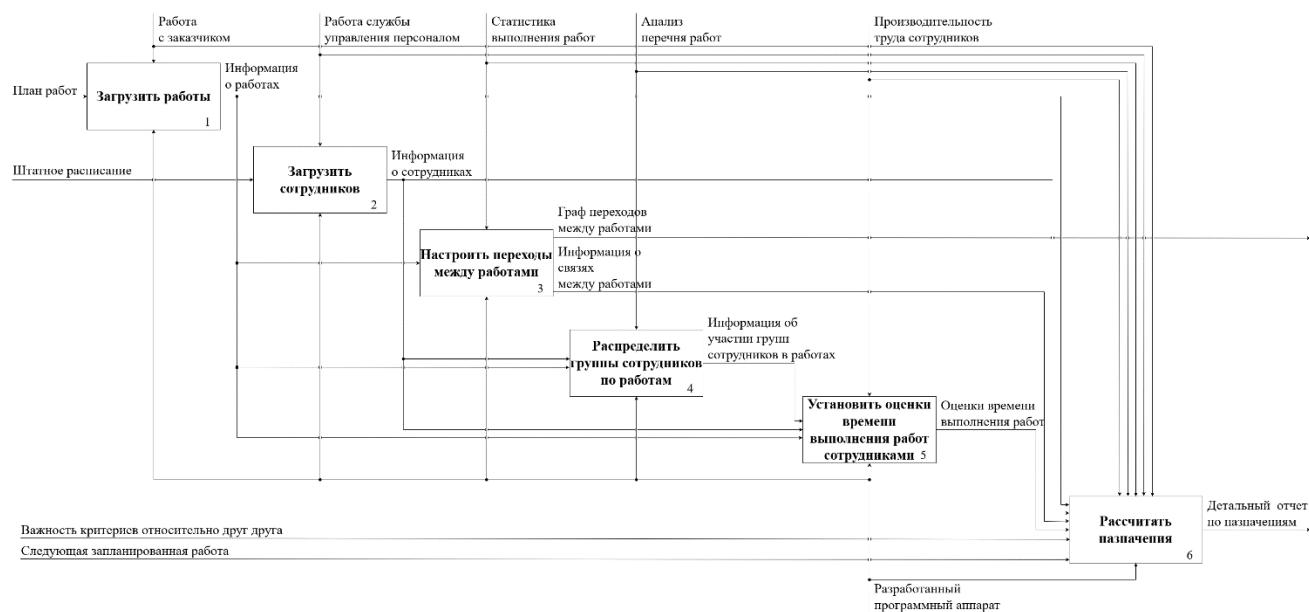
Таким образом, обобщая основные подходы к решению задачи корректной организации командной работы над проектом [20-31], отметим следующее:

- присущая неточность в априорных предпочтениях критериев и альтернатив по критериям может привести к неустойчивым приоритетам и ненадежному ранжированию альтернатив;
- многоцелевой характер постановок задач о назначении;
- многокритериальность, обусловленная вектором локальных критериев и интегральных показателей (например, общее время реализации проекта и совокупная стоимость проекта);
- необходимость высокопроизводительных вычислений при больших наборах исходных данных (число задач может исчисляться тысячами);
- между различными операциями и исполнителями существует взаимосвязь «многие ко многим» и др.

Уместно также отметить несколько популярных инструментов в рамках задач корректной актуализации оценок работников и формирования их приоритетов относительно конкретной работы:

- платформа Grow от компании EPAM не предоставляет возможности автоматического оценивания разработчика, но предоставляет матрицу компетенций и варианты достижения целей для каждого уровня развития;
- система оценивания работника E-Staff направлена на оценивание работников на этапе трудоустройства (с платным распространением и внедрением), формирует приоритизированный список работников, основываясь на резюме и данных из интернета; имеет ограничение на размер массива данных, обрабатываемых в реальном режиме времени и не ставит целью ранжирования предпочтений при выборе работников;
- инструменты автоматической генерации и оценки резюме на западных рынках, таких, как Zety, Resume.io, Enhancv, Rezi, использующие в том числе методы искусственного интеллекта для персонализации текстов, но не преследующие цель многокритериального ранжирования работников относительно специфики отдельной работы.

**4. Предлагаемое авторами решение задачи. Модель оптимизации назначений в условиях больших данных.** В основе программной реализации модели, схематично представленной на рис. 1, находится прототип со структурой, приведенной на рис. 3.



**Рис. 3.** Функциональная схема прототипа программы автоматизации процесса анализа в задаче оптимизации распределения работ (согласно нотации IDEF-0)

Решением основной задачи является автоматизированная процедура реализации политики назначений работников на работы, при этом важна реальность времени принятия решения при большой мощности динамически изменяемого множества альтернатив в виде пар (работа, работник). Корректный учет последнего наиболее критичен, так как в реальном рабочем процессе появление новых пар, подлежащих сравнению, удаление из набора альтернатив – явление нередкое, а, например, классический метод парных сравнений, как известно [32-35], в этом случае может выдать ошибки ранжирования в виде нарушения ранее полученных предпочтений.

Алгоритм ранжирования альтернатив относительно фиксированной работы на предмет выбора работника состоит из двух частей, первая из которых представляет собой классический метод анализа иерархий [32] (Analytical Hierarchy Process (AHP)), с выше отмеченной некорректностью при решении задачи ранжирования и весьма ограничительный при больших мощностях анализируемых множеств альтернатив и критериев.

Напомним кратко основные позиции АНР в терминах данной статьи для лучшего понимания ниже следующих алгоритмов АНР+ и АНР++ и большей прозрачности развития дальнейшей идеи применения метода оценки альтернатив для ранжирования большого объема альтернатив.

**Алгоритм АНР.** Как хорошо известно [32], выходом этого алгоритма является взвешенная оценка каждой альтернативы по совокупности критериев.

*Входные данные:* множество альтернатив  $\{A_i | i = \overline{1, N_a}\}$ ; множество критериев  $\{C_j | j = \overline{1, N_c}\}$ , где  $N_c$  – количество критериев оценивания.

1. Экспертное назначение предпочтений критериев  $v(C_j), j = \overline{1, N_c}, \sum_{j=1}^{N_c} v(C_j) = 1$ , отражающее их относительную значимость.
2. Определение относительных предпочтений альтернатив:  $d_{ij} = d(A_i/C_j), i = \overline{1, N_a}, j = \overline{1, N_c}$  («вес» альтернативы  $A_i$  в соответствии с критерием (показателем)  $C_j$ ).
3. Формирование согласованных (с соблюдением свойства транзитивности) матриц парных сравнений  $F_j = \|f_{ik}(j)\| = \left\| \frac{d_{ij}}{d_{kj}} \right\|_{N_a \times N_a}, i, k = \overline{1, N_a}$  относительно каждого  $j$ -го критерия,

и вычисление собственных векторов матриц парных сравнений критериев  $C = \|C_{ij}\| = \|v(C_j)/v(C_l)\|$ ,  $j, l = \overline{1, N_C}$  и альтернатив  $F_j, j = \overline{1, N_C}$  с последующей их нормализацией (символ «\*» означает результат операции нормализации вектора):

$$4. C^* = \|v_j^*\|_{1 \times N_C}, f_j^* = (a_{1j}^*, \dots, a_{N_A j}^*)^T, j = \overline{1, N_C}.$$

5. Получение вектора  $\mathbf{u}$ , элементы которого есть итоговые значения многокритериального оценивания альтернатив в виде их весовых коэффициентов  $u_i = \sum_{j=1}^{N_C} v_j^* a_{ij}^*$ ,  $i = \overline{1, N_A}$  с последующей их нормализацией  $\mathbf{u}^* = \|u_i^*\|_{1 \times N_A}$ .

*Выходные данные:* вектор итоговых оценок альтернатив  $\mathbf{u}^* = \mathbf{u}^{\text{норм}}$ .

В матричном виде итог алгоритма АНР+ имеет вид:

$$\mathbf{u} = \mathbf{F}^* \times \mathbf{C}^{*T}, \mathbf{F}^* = (f_1^* \quad \dots \quad f_{N_C}^*) = \begin{pmatrix} a_{11}^* & \dots & a_{1N_C}^* \\ \dots & \dots & \dots \\ a_{N_A 1}^* & \dots & a_{N_A N_C}^* \end{pmatrix}, \sum_{i=1}^{N_A} a_{ij}^* = 1, j = \overline{1, N_C}.$$

*Замечание 2.* В ряде работ [33-37] указаны нежелательные особенности данного алгоритма: нарушение соотношений для ранее полученных рангов при добавлении новых альтернатив, проблемы с непосредственным использованием числовых критериев.

**Алгоритм АНР+ как корректное обобщение АНР.** За счет выполнения дополнительных операций [33, 35]: а) попарной группировки компонент векторов  $f_j^* = (a_{1j}^*, \dots, a_{N_A j}^*)^T, j = \overline{1, N_C}$ ; б) операции нормализации весовых коэффициентов по каждой группе; в) линейной скаляризации полученных оценок отдельной альтернативы из каждой группы по всем критериям, итоговые оценки весов альтернатив будут свободны от основного недостатка, а именно, – нарушения ранее достигнутых предпочтений при добавлении в набор новых альтернатив (нарушение аксиомы К. Эрроу [34] о независимости предпочтений).

*Входные данные:* вектор критериальных предпочтений  $\mathbf{C}^*$  и матрица  $\mathbf{D}$ , столбцы которой есть нормализованные векторы матриц парных сравнений по соответствующим критериям.

1. Формирование матрицы парных сравнений  $\mathbf{D}_j, j = \overline{1, N_C}$ , с элементами в виде двухкомпонентных векторов

$$\mathbf{D}_j = \|\mathbf{d}_j(i, k)\|_{N_A \times N_A}, \mathbf{d}_j(i, k) = [a_{ij}^{**}(i) \quad a_{kj}^{**}(k)], i, k = \overline{1, N_A}, j = \overline{1, N_C},$$

компоненты которых имеют значения относительных оценок по каждой паре альтернатив по отдельному критерию  $j$  (символ «\*\*» означает результат операции нормализации в паре элементов):

$$a_{ij}^{**}(i) = \frac{a_{ij}^*(i)}{(a_{ij}^*(i) + a_{kj}^*(k))}, a_{kj}^{**}(k) = \frac{a_{kj}^*(k)}{(a_{ij}^*(i) + a_{kj}^*(k))}, i, k = \overline{1, N_A}, j = \overline{1, N_C}.$$

*Замечание 3.* Индексы в обозначении  $\mathbf{d}_j(i, k)$  означают следующее:  $(i, k)$  есть адрес элемента матрицы  $\mathbf{D}_j$  представляющего собой относительный вес альтернатив  $A_i$  и  $A_k$  только в данной паре альтернатив по критерию  $C_j$ , и  $a_{ij}^{**}(i) + a_{kj}^{**}(k) = 1, i, k = \overline{1, N_A}, j = \overline{1, N_C}$ .

2. Формирование матрицы  $\bar{\mathbf{D}} = \|\bar{\mathbf{d}}(i, k)\|_{N_A \times N_A}$  с векторными элементами, компоненты которых представляют собой результат скаляризации (линейную свертку) соответствующих компонент по всем критериям:

$$\bar{\mathbf{d}}(i, k) = (\bar{\mathbf{d}}(i), \bar{\mathbf{d}}(k)), \\ \bar{\mathbf{d}}(i) = \sum_{j=1}^{N_C} v_j^* a_{ij}^{**}(i), \bar{\mathbf{d}}(k) = \sum_{j=1}^{N_C} v_j^* a_{kj}^{**}(k), i, k = \overline{1, N_A}.$$

3. Нормализация элементов матрицы  $\bar{\mathbf{D}}$ :

$$\bar{d}^*(i) = \frac{\bar{d}(i)}{\bar{d}(i) + \bar{d}(k)}, \bar{d}^*(k) = \frac{\bar{d}(k)}{\bar{d}(i) + \bar{d}(k)}, \bar{d}^*(i) + \bar{d}^*(k) = 1, i, k = \overline{1, N_A}.$$

4. Итоговое определение весовых коэффициентов альтернатив  $d(A_i), i = \overline{1, N_A}$ , как сумма первых компонентов  $i$ -й строки матрицы  $\bar{D}^* = \|\bar{d}^*(i, k)\|_{N_A \times N_A}, \bar{d}^*(i, k) = (\bar{d}^*(i), \bar{d}^*(k)), d(A_i) = \sum_{l=1}^{N_A} \bar{d}^*(i, l)$ , с последующей нормализацией вектора весовых коэффициентов альтернатив, получаем итоговый набор  $d^*(A_i), i = \overline{1, N_A}$ .

*Выходные данные:* вектор оценок весовых коэффициентов альтернатив  $d^*(A_i), i = \overline{1, N_A}$ , свободных от недостатков АНР.

*Замечание 4.* Вычислительная трудоемкость алгоритма АНР+ оценивается как  $O(N_A^2 N_C)$ . Алгоритм АНР+ предъявляет достаточно высокие требования к оперативной памяти.

Финальный алгоритм АНР++, обобщающий АНР+ на ранжирование больших данных, основан на декомпозиции исходной задачи выбора на всем множестве альтернатив на последовательность задач выбора на парах альтернатив со всеми вытекающими положительными последствиями относительно проблем используемых вычислительных ресурсов.

С целью решения данной проблемы в работе [36] была предложена декомпозиция исходной задачи выбора на всем множестве альтернатив на последовательность задач выбора на паре альтернатив, выполнение каждой из которых интерпретируется как функция сравнения двух элементов согласно алгоритму сортировки числовой последовательности.

Применительно к рассматриваемым здесь задачам алгоритм АНР+, обеспечивающий непротиворечивое оценивание альтернатив при динамическом пополнении набора большой размерности, будет иметь следующее описание.

**Алгоритм АНР++.** Обобщение корректного алгоритма АНР+ для больших динамически пополняемых наборов альтернатив применительно к поставленной задаче имеет следующее описание.

*Входные данные:* вектор критериальных предпочтений  $C^*$  относительно характеристик работника (см. цифровую карточку на рис. 3) и последовательность альтернатив  $A = \{A_{i_{j_0}}\}, A_{i_{j_0}} = \{w_i, e_{j_0}\}, i = \overline{1, N_w}, j_0 = \overline{1, N_e}$ ; индекс  $j_0$  фиксирует вид работы, для которой осуществляется выбор работника.

Выбор алгоритма сортировки числового массива (весовых коэффициентов альтернатив):

1. Поступательное сравнение пары альтернатив  $A_{kj_0}, A_{lj_0}$ .
2. Применение алгоритма АНР+ для пары  $A_{kj_0}, A_{lj_0}$  с выходом в виде значений их весовых коэффициентов  $a_{kj_0}, a_{lj_0}$ .
3. Сравнение значений  $a_{kj_0}, a_{lj_0}$  и, при необходимости, их перестановка по убыванию весов согласно цели – получение отсортированной последовательности  $R$ .
4. Переход на шаг 1 и далее повторение п. 2–4, пока имеют место необработанные альтернативы.
5. Осуществить сортировку слиянием отсортированных частей при выборе соответствующего алгоритма сортировки при необходимости.
6. Вывод ранжированного массива оценок  $R$ .

*Замечание 5.* Согласно свойствам алгоритма АНР+ при добавлении в множество сравниваемых альтернатив дополнительной альтернативы ранее достигнутые предпочтения не нарушаются, но весовые коэффициенты альтернатив могут измениться. В этой связи применима любая быстрая сортировка в силу благоприятного изначального расположения элементов. В силу нарушения аксиомы К. Эрроу [34] о независимости предпочтений, алгоритм

АНР не может быть обобщен для больших данных на основе данного приема. Таким образом, решение задачи ранжирования для сколь угодно больших массивов данных (работа, работник) стало возможным только на основе АНР+ [33, 35].


*Выходные данные:* численно ранжированные наборы предпочтений работников относительно фиксированных работ  $j_0$  при изменении индекса  $j_0$  в требуемом промежутке.

*Замечание 6.* Алгоритмическая сложность последнего алгоритма, таким образом, определяется способом сортировки.

**Сравнение решений многокритериального ранжирования набора альтернатив.** Свойства алгоритма АНР++ (высокая скорость ранжирования в условиях big data, неприязнательность к используемым вычислительным ресурсам (табл. 2, рис. 4)), таким образом, обусловлены исключительно корректной модификацией АНР+ [33, 35], поскольку каждая итерация основана на применении АНР+ только для пары элементов [36].

**Таблица 2.** Сравнительные характеристики результатов ранжирования альтернатив-назначений в зависимости от основных параметров алгоритмов в условиях трех критериев

Параметры алгоритмов ранжирования	Длительность выполнения (с)/объем используемой памяти (мб)		
	Корректное расширение классического АНР+	расширение алгоритма	Алгоритм оптимизации АНР++ для больших данных
Число альтернатив ( $N_A$ )			
3000	7/648		0.116/28
10 000	-/-		0.240/51
100 000	-/-		1.965/274



**Рис. 4.** Результат сравнения длительности операции ранжирования в задаче оптимизации распределения работ

На основе алгоритма АНР++ применительно к задаче выбора в контексте статьи будем иметь выходные данные (оптимальное распределение работников  $E$  на отдельный вид работ  $W$ ), в виде матрицы:

$$Y = \|y_{ij}\|_{n \times m},$$

где  $y_{ij}$  – признак назначения на работу  $w_i$  работника  $e_j$ ,  $i = \overline{1, N_w}$ ,  $j = \overline{1, N_e}$ ;  $N_w$  – количество работ;  $N_e$  – число работников, где матрица  $Y$  может содержать следующие значения:

- $y_{ij} = 1$ , если работник  $e_j$  назначен на работу  $w_i$ ;
- $y_{ij} = 0$ , если работник  $e_j$  не назначен на работу  $w_i$ , но может в ней участвовать;
- $y_{ij} = -1$ , если работник  $e_j$  не может участвовать в работе  $w_i$ .

**Заключение.** Рассмотрена задача оптимизации управления назначением множества работ в процессе реализации крупных программных проектов, особенностью которых является динамическое перераспределение большого объема работ в изменяющихся условиях внешнего и внутреннего характера.

Поскольку задача оптимального распределения трудовых ресурсов имеет высокую вариативность и относится к классу задач с большим объемом данных, для ее решения привлечена корректная (непротиворечивая и алгоритмически не улучшаемая) модификация метода парных сравнений, ориентированная именно на высокоразмерные динамически изменяемые матричные массивы.

В качестве базовой функциональной модели для описания динамики выполнения работ в рамках данного исследования выбран инструмент стохастического моделирования – цепь Маркова, исключительно с целью продемонстрировать возможность формализации всего процесса реализации программного проекта большой сложности.

Заявленные свойства предложенного алгоритма, а именно, существенное преимущество по вычислительным ресурсам (табл. 2, рис. 4) перед классическим ранжированием альтернатив подтверждено численным моделированием в условиях больших данных.

Предложенный к использованию алгоритм назначений является адаптивным и позволяет корректировать связи «работа-работник» в режиме реального времени в неблагоприятных условиях, тем самым повышая устойчивость процесса планирования.

#### Список источников

1. Williams M. The principles of project management. Australia, Site Point Pty. Ltd., 2008, 193 p.
2. Ньютон Р. Управление проектами от А до Я. – М.: Альпина Бизнес Букс, 2007. – 180 с.
3. Макконнелл С. Сколько стоит программный проект / С. Макконнелл – М.: Русская Редакция, СПб.: Питер, 2007. – 297 с.
4. Larson E.W., Gray C.F. Project management: the management process. 8th ed. McGraw Hill, 2021, 704 p.
5. Ермаков Е.В. Применение гибридных методологий в управлении проектами / Е.В. Ермаков // Universum: экономика и юриспруденция, 2024. – 9(119).
6. Охтилев М.Ю. Производство программ. Инженерный подход: монография / М.Ю. Охтилев, В.Н. Коромысличенко, П.А. Охтилев. – Москва; Вологда: Инфра-Инженерия, 2024 – 140 с.
7. Loureiro E., Gomes B., Varajão J., Silva C. Information systems project success surveys - Insights from the last 30 years. Heliyon, 2024, vol. 10 (23), e40619, DOI: 10.1016/j.heliyon.2024.e40619.
8. Iriarte C., Bayona S. IT projects success factors: a literature review, International Journal of Information Systems and Project Management. 2020, vol. 8(2), pp. 49-78, DOI: 10.12821/ijispm080203.
9. Massimo R., Zenezini G., Ottaviani F.M. et al. Project management information systems: a systematic review. Procedia Computer Science, 2025, vol. 256, pp. 1739-1747, DOI: 10.1016/j.procs.2025.02.313.
10. PMBOK Guide. 8th ed. Newton Square, Pennsylvania, USA: Project Management Institute, 2025.
11. Standish Group et al. CHAOS report 2020. The Standish Group International, Inc. 2020, pp. 1-13.
12. Guzman E., Andres B., Poler R. Models and algorithms for production planning, scheduling and sequencing problems: a holistic framework and a systematic review. Journal of Industrial Information Integration, 2021, vol. 27, no. 2, p. 100287, DOI: 10.1016/j.jii.2021.100287.
13. Barros L., Tam C., Varajão J. Agile software development projects – unveiling the human-related critical success factors. Information and Software Technology, 2024, vol. 170, p. 107432, DOI: 10.1016/j.infsof.2024.107432.
14. Rath S.P., Jain N.K., Tomer G. et al. A systematic literature review of agile software development projects. Information and Software Technology, Elsevier, 2025.
15. Annosi M.C., Appio F.P., Martini A. Institutional context and agile team innovation: a sensemaking approach to collective knowledge creation. Technovation, 2024, vol. 129, p. 102894, DOI: 10.1016/j.technovation.2023.102894.

16. Batista T., Bronzo M., Barbosa M.W. The effects of big data analytics capabilities on agile software development practices and project performance: a dynamic capabilities view perspective. *International Journal of Managing Projects in Business*, 2025, vol. 18, no. 3, pp. 479–505.
17. Washizaki H. Guide to the software engineering body of knowledge v4.0. IEEE Computer Society, 2025, 413 p.
18. Тимофеев Д.А. Описание процессов разработки программ с помощью скрытых марковских моделей / Д.А. Тимофеев, А.В. Самочадин // Научно-технические ведомости СПбГПУ, 2017. – Т. 10. – № 4. – С. 70-77.
19. Savchuk T. Modeling of software development process with the Markov processes. *Eastern-European Journal of Enterprise Technologies*, 2017, vol. 3, no. 2, pp. 33-38, DOI: 10.15587/1729-4061.2017.103340.
20. Колесникова Е.В. Разработка марковской модели состояний проектно управляемой организации / Е.В. Колесникова, В.А. Вайсман, С.А. Величко // Суч. технології в машинобуд.: зб. наук. праць. – НТУ «ХПІ», 2012. – №7. – С. 217-223.
21. Михальцова Е.В. Разработка модели оптимизации и метода распределения работ при управлении проектами в области информационных технологий: специальность 08.00.13 «Математические и инструментальные методы экономики»: диссертация на соискание ученой степени кандидата экономических наук / Михальцова Елена Викторовна; Московский государственный университет экономики, статистики, информатики. – Москва, 2009. – 133 с.
22. Дегтерев Д.А. Математические методы решения задачи составления цеховых расписаний / Д.А. Дегтерев, А.С. Дегтерев // Вестник Сибирского государственного аэрокосмического университета имени академика М. Ф. Решетнева, 2011. – Т.12. – №5. – С. 29-34.
23. Карпов В.И. Оптимизация календарного плана выполнения комплекса взаимосвязанных работ в системе поддержки принятия решений / В.И. Карпов // Прикладная информатика, 2014. – №4(52). – С. 101-108.
24. Garcia-Zamora D., Labella Á., Ding W. et al. Large-scale group decision making: a systematic review and a critical analysis. *IEEE/CAA Journal of Automatica Sinica*, 2022, vol. 9, no. 6, pp. 949-966, DOI: 10.1109/JAS.2022.105617.
25. Magabaleh A.A., Ghraibeh L.L., Audeh A.Y. et al. Systematic review of software engineering uses of multi-criteria decision-making methods: Trends, bibliographic analysis, challenges, recommendations, and future directions. *Applied Soft Computing*, 2024, vol. 163, DOI: 10.1016/j.asoc.2024.111859.
26. Yu X., Dai H., Li L. et al. Finding the best learning to rank algorithms for effort-aware defect prediction. *Information and Software Technology*, 2023, vol. 157, p. 107162, DOI: 10.1016/j.infsof.2023.107165.
27. Xiao J., Gao Q., Yang Z. et al. Multi-round auction-based resource allocation for edge computing: maximizing social welfare. *Future Generation Computer Systems*, 2023, vol. 140, pp. 365-375, DOI: 10.1016/j.future.2022.10.028.
28. Börstler J., N. bin Ali, Petersen K. et al. Acceptance behavior theories and models in software engineering – A mapping study. *Information and Software Technology*, 2024, vol. 172, DOI: 10.1016/j.infsof.2024.107469.
29. Shao L., Liu J., Fu C. et al. Alternative ranking in trust network group decision-making: A distributionally robust optimization method. *European Journal of Operational Research*, 2025, vol. 327, iss. 3, pp. 986-1002m DOI: 10.1016/j.ejor.2025.05.052.
30. Lu C., Li X., Gao L. et al. An effective multi-objective discrete virus optimization algorithm for flexible job-shop scheduling problem with controllable processing times. *Computers & Industrial Engineering*, 2017, vol. 104, pp. 156–174, DOI:10.1016/j.cie.2016.12.020.
31. Xu W., Xu Sh., Liang J. et al. A discrete water source cycle algorithm design for solving production scheduling problem in flexible manufacturing systems. *Swarm and Evolutionary Computation*, 2025, vol. 94, DOI: 10.1016/j.swevo.2025.101897.
32. Saaty T.L. Absolute and relative measurement with the ANP. The most livable cities in the United States. *Socio-Economic Planning Sciences*, 1986, vol. 20, no. 6. pp. 327–331, DOI: 10.1016/0038-0121(86)90043-1.
33. Самохвалов Ю.Я. Групповой учет относительного превосходства альтернатив в задачах принятия решений / Ю.Я. Самохвалов // Кибернетика и системный анализ, 2003. – № 6. – С. 141-145.
34. Эрроу К.Дж. Коллективный выбор и индивидуальные ценности / К.Дж. Эрроу. – М.: ГУ ВШЭ, 2004. – 201 с.
35. Колесникова С.И. Модификация метода анализа иерархий для динамических наборов альтернатив / Е.В. Колесникова // Прикладная дискретная математика, 2009. – № 4(6). – С. 102-109.
36. Колесникова, С.И. Оптимизация алгоритма многокритериального выбора с динамически пополняемым большим набором альтернатив / С.И. Колесникова, С.А. Караванова // Информационные технологии, 2021. – Т. 27. – № 5. – С. 235-241.
37. Подиновский В.В. Парето-оптимальные решения многокритериальных задач / В.В. Подиновский, В.Д. Ногин. – М.: Наука, 2007. – 256 с.

**Колесникова Светлана Ивановна.** Д.т.н., профессор кафедры компьютерных технологий и программной инженерии Института вычислительных систем и программирования Санкт-Петербургского государственного университета аэрокосмического приборостроения. Научные интересы включают нелинейное управление с неопределенностью в описании, интеллектуальный анализ данных. AuthorID: 150312, SPIN: 1928-8626, ORCID: 0000-0001-7158-2747, skolesnikova@yandex.ru. 190000, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А.

**Фоменкова Анастасия Алексеевна.** Доцент кафедры компьютерных технологий и программной инженерии Института вычислительных систем и программирования Санкт-Петербургского государственного университета аэрокосмического приборостроения. Научные интересы: технологии программной инженерии, биотехнологии, мониторинг сложных биосистем. AuthorID: 1126590, SPIN: 3606-1805, ORCID: 0000-0002-5570-6743, a.a.fomenkova@mail.ru. 190000, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А.

**Поляков Виктор Валерьевич.** Аспирант кафедры компьютерных технологий и программной инженерии Института вычислительных систем и программирования Санкт-Петербургского государственного университета аэрокосмического приборостроения. Научные интересы: технологии разработки больших проектов, модели оптимизации обработки больших данных. AuthorID: 1267137, SPIN: 1914-4619, ORCID: 0009-0005-9314-4752, viktorpolyakov1999@mail.ru. 190000, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А.

---

UDC 519.7

DOI:10.25729/ESI.2026.42.2.006

## Optimization of assignment of a large number of works in the problem of managing team project implementation

Svetlana I. Kolesnikova, Anastasiya A. Fomenkova, Viktor V. Polyakov

St.Petersburg State University of Aerospace Instrumentation,  
Russia, St. Petersburg, skolesnikova@yandex.ru

**Abstract.** A problem of control assignment of works with a large dynamically replenished (changed) volume of them is considered. Despite existing tools for automating large-scale software development (AGILE products, Waterfall, and others), the challenge of promptly and correctly intervening in their production process under changing external and internal conditions remains acute due to the resulting negative consequences (project delays, budget overruns, and unfinished projects due to unsatisfactory quality). The most pressing issue in large projects is the optimal assignment of work in accordance with the established current competencies of employees. However, several studies (such as surveys from Scrum Inc.) have noted that the relationship between the implementation of the most popular Agile products and increased software development efficiency is inconsistent. For this reason, developing improvements to existing tools is relevant for managing the production of large software projects, where interrelated resource constraints time, cost, and computational are particularly acute. The objective of this study is to present a model and its implementing algorithm for optimizing the work assignment process with a focus on big data (from the perspective of the developer), resulting in exponential gains in time and resources when comparing options in the form of alternatives (job, worker). A distinctive feature of the model is an optimal algorithm for ranking a large number of options, executed in real time, and resulting in a virtually unimprovable correct solution to the problem of sorting a dynamically replenished set of alternatives, which corresponds to the most important principle of “here and now” development, consisting of an immediate response to changing conditions and customer requirements. The gain is achieved through a non-mechanical combination of three methods: the classical paired comparison method, its modification, correct in the sense of K. Arrow's axiom on the independence of choice (preferences) from previously achieved rankings, and the selected algorithm for sorting the numerical sequence. Examples of numerical simulation are provided, confirming the declared characteristics of the algorithm for selecting the optimal alternative (job, worker) in a big data environment.

**Keywords:** poorly formalizable object, decision-making algorithms, project management, dynamic work assignment model, big data, modification of the pairwise comparison method for big data, collective of evaluation algorithms, Markov chain

### References

1. Williams M. The principles of project management. Australia, Site Point Pty. Ltd., 2008, 193 p.
2. Newton R. Upravleniye proyektami ot A do YA. [Project management from A to Z]. Moskva: Al'pina Biznes Buks [Moscow: Russian edition], 2007, 180 p.

3. Makkonnell S. Skol'ko stoit programmnyj proekt [How much does a software project cost]. Economics and jurisprudence: electronic scientific journal [Moscow: Russian edition], Sankt-Peterburg: Piter [St. Petersburg: Peter], 2007, 297 p.
4. Larson E.W., Gray C.F. Project management: the management process. 8th ed. McGraw Hill, 2021, 704 p.
5. Ermakov E.V. Primeneniye gibridnykh metodologiy v upravlenii proyektami [Application of hybrid methodologies in project management]. Universum: ekonomika i yurisprudentsiya: elektron. nauchn. Zhurnal, [Economics and jurisprudence: electronic scientific journal], 2024, 9(119).
6. Ohtilev M.Ju. Proizvodstvo programm. Inzhenernyj podhod: monografiya [Production of programs. The engineering approach: a monograph]. Moskva; Vologda: Infra-Inzheneriya [Moscow; Vologda: Infra-Engineering], 2024, 140 p.
7. Loureiro E., Gomes B., Varajão J., Silva C. Information systems project success surveys - Insights from the last 30 years. Heliyon, 2024, vol. 10 (23), e40619, DOI: 10.1016/j.heliyon.2024.e40619.
8. Iriarte C., Bayona S. IT projects success factors: a literature review, International Journal of Information Systems and Project Management. 2020, vol. 8(2), pp. 49-78, DOI: 10.12821/ijispm080203.
9. Massimo R., Zenezini G., Ottaviani F.M. et al. Project management information systems: a systematic review. Procedia Computer Science, 2025, vol. 256, pp. 1739-1747, DOI: 10.1016/j.procs.2025.02.313.
10. PMBOK Guide. 8th ed. Newton Square, Pennsylvania, USA: Project Management Institute, 2025.
11. Standish Group et al. CHAOS report 2020. The Standish Group International, Inc. 2020, pp. 1-13.
12. Guzman E., Andres B., Poler R. Models and algorithms for production planning, scheduling and sequencing problems: a holistic framework and a systematic review. Journal of Industrial Information Integration, 2021, vol. 27, no. 2, p. 100287, DOI: 10.1016/j.jii.2021.100287.
13. Barros L., Tam C., Varajão J. Agile software development projects – unveiling the human-related critical success factors. Information and Software Technology, 2024, vol. 170, p. 107432, DOI: 10.1016/j.infsof.2024.107432.
14. Rath S.P., Jain N.K., Tomer G. et al. A systematic literature review of agile software development projects. Information and Software Technology, Elsevier, 2025.
15. Annosi M.C., Appio F.P., Martini A. Institutional context and agile team innovation: a sensemaking approach to collective knowledge creation. Technovation, 2024, vol. 129, p. 102894, DOI: 10.1016/j.technovation.2023.102894.
16. Batista T., Bronzo M., Barbosa M.W. The effects of big data analytics capabilities on agile software development practices and project performance: dynamic capabilities view perspective. International Journal of Managing Projects in Business, 2025, vol. 18, no. 3, pp. 479–505.
17. Washizaki H. Guide to the software engineering body of knowledge v4.0. IEEE Computer Society, 2025, 413 p.
18. Timofeev D.A. Opisaniye processov razrabotki programm s pomoshh'ju skrytyh markovskikh modelej [Description of software development processes using hidden Markov models]. Nauchno-tehnicheskie vedomosti SPbGPU [Scientific and technical bulletin of SPbPU], 2017, vol. 10, no. 4, pp. 70-77.
19. Savchuk T. Modeling of software development process with the Markov processes. Eastern-European Journal of Enterprise Technologies, 2017, vol. 3, no. 2, pp. 33-38, DOI: 10.15587/1729-4061.2017.103340.
20. Kolesnikova E.V. Razrabotka markovskoj modeli sostojanij proektno upravljajemoj organizacii [Development of a Markov model of the states of a project-driven organization]. Suchasni tekhnologii v mashinobuduvanni [Modern Technologies in Mechanical Engineering], NTU "KhPI", 2012, no.7, pp. 217-223.
21. Mihal'cova E.V. Razrabotka modeli optimizacii i metoda raspredelenija rabot pri upravlenii proektami v oblasti informacionnyh tehnologij: special'nost' 08.00.13 «Matematicheskie i instrumental'nye metody jekonomiki»: dissertacija na soiskanie uchenoj stepeni kandidata jekonomicheskikh nauk [Development of an optimization model and a method for distributing work in project management in the field of information technology: specialty 08.00.13 «Mathematical and instrumental methods of Economics»: dissertation for the degree of Candidate of Economic Sciences], Moskva, 2009, 133 p.
22. Degterev D.A. Matematicheskie metody reshenija zadachi sostavlenija cehovyh raspisanij [Mathematical methods for solving the problem of drawing up shop schedules]. Vestnik Sibirskogo gosudarstvennogo aerokosmicheskogo universiteta imeni akademika M.F. Reshetneva [Bulletin of Reshetnev Siberian State Aerospace University], 2011, vol.12, no.5, pp. 29-34.
23. Karpov V.I. Optimizacija kalendarnogo plana vypolnenija kompleksa vzaimosvjazannyh rabot v sisteme podderzhki prinjatija reshenij [Optimization of the calendar plan for the execution of a complex of interrelated works in the decision support system]. Prikladnaya informatika [Applied Informatics], 2014, no.4(52), pp. 101-108.
24. Garcia-Zamora D., Labella Á., Ding W. et al. Large-scale group decision making: a systematic review and a critical analysis. IEEE/CAA Journal of Automatica Sinica, 2022, vol. 9, no. 6, pp. 949-966, DOI: 10.1109/JAS.2022.105617.

25. Magabaleh A.A., Ghraibeh L.L., Audeh A.Y. et al. Systematic review of software engineering uses of multi-criteria decision-making methods: Trends, bibliographic analysis, challenges, recommendations, and future directions. *Applied Soft Computing*, 2024, vol. 163, DOI: 10.1016/j.asoc.2024.111859.
26. Yu X., Dai H., Li L. et al. Finding the best learning to rank algorithms for effort-aware defect prediction. *Information and Software Technology*, 2023, vol. 157, p. 107162, DOI: 10.1016/j.infsof.2023.107165.
27. Xiao J., Gao Q., Yang Z. et al. Multi-round auction-based resource allocation for edge computing: maximizing social welfare. *Future Generation Computer Systems*, 2023, vol. 140, pp. 365-375, DOI: 10.1016/j.future.2022.10.028.
28. Börstler J., N. bin Ali, Petersen K. et al. Acceptance behavior theories and models in software engineering – A mapping study. *Information and Software Technology*, 2024, vol. 172, DOI: 10.1016/j.infsof.2024.107469.
29. Shao L., Liu J., Fu C. et al. Alternative ranking in trust network group decision-making: A distributionally robust optimization method. *European Journal of Operational Research*, 2025, vol. 327, iss. 3, pp. 986-1002m DOI: 10.1016/j.ejor.2025.05.052.
30. Lu C., Li X., Gao L. et al. An effective multi-objective discrete virus optimization algorithm for flexible job-shop scheduling problem with controllable processing times. *Computers & Industrial Engineering*, 2017, vol. 104, pp. 156–174, DOI:10.1016/j.cie.2016.12.020.
31. Xu W., Xu Sh., Liang J. et al. A discrete water source cycle algorithm design for solving production scheduling problem in flexible manufacturing systems. *Swarm and Evolutionary Computation*, 2025, vol. 94, DOI: 10.1016/j.swevo.2025.101897.
32. Saaty T.L. Absolute and relative measurement with the AHP. The most livable cities in the United States. *Socio-Economic Planning Sciences*, 1986, vol. 20, no. 6. pp. 327–331, DOI: 10.1016/0038-0121(86)90043-1.
33. Samohvalov, Ju.Ja. Gruppovoj uchet odnositel'nogo prevoshodstva al'ternativ v zadachah prinjatija reshenij [Group consideration of the relative superiority of alternatives in decision-making tasks]. *Kibernetika i sistemnyj analiz [Cybernetics and system analysis]*, 2003, no. 6, pp. 141-145.
34. Jerrou K. Dzh. Kollektivnyj vybor i individual'nye cennosti [Collective choice and individual values]. Moskva: GU VShJe [Moscow: HSE], 2004, 201 p.
35. Kolesnikova S.I. Modifikacija metoda analiza ierarhij dlja dinamicheskikh naborov al'ternativ [Modification of the hierarchy analysis method for dynamic sets of alternatives]. *Prikladnaja diskretnaja matematika [Applied discrete mathematics]*, 2009, no. 4(6), pp. 102-109.
36. Kolesnikova, S.I. Optimizacija algoritma mnogokriterial'nogo vybora s dinamicheski popolnjaemym bol'shim naborom al'ternativ [Optimization of a multi-criteria choice algorithm with a dynamically expanding large set of alternatives]. *Informatsionnyye tekhnologii [Information Technologies]*, 2021, vol. 27, no. 5, pp. 235-241.
37. Podinovskij V.V., Nogin V. D. Pareto-optimal'nye reshenija mnogokriterial'nyh zadach [Pareto-optimal solutions to multi-criteria problems]. Moskva: Nauka [Science], 2007, 256 p.

**Kolesnikova Svetlana Ivanovna.** Doctor of Technical Sciences, Professor, Department of Computer Technologies and Software Engineering, Institute of Computing Systems and Programming, St. Petersburg State University of Aerospace Instrumentation. Scientific interests include non-linear control with uncertainty in the description, data mining. AuthorID: 150312, SPIN: 1928-8626, ORCID: 0000-0001-7158-2747, skolesnikova@yandex.ru. 190000, St. Petersburg, st. Bolshaya Morskaya, 67, lit. A.

**Fomenkova Anastasiya Alekseevna.** Postgraduate student of the Department of Computer Technologies and Software Engineering, Institute of Computing Systems and Programming, St. Petersburg State University of Aerospace Instrumentation. Scientific interests: technologies for developing large projects, models for optimizing big data processing. AuthorID: 1126590, SPIN: 3606-1805, ORCID: 0000-0002-5570-6743, a.a.fomenkova@mail.ru. 190000, St. Petersburg, st. Bolshaya Morskaya, 67, lit. A.

**Polyakov Viktor Valerievich.** Associate Professor, Department of Computer Technology and Software Engineering, Institute of Computing Systems and Programming, Saint Petersburg State University of Aerospace Instrumentation. Scientific interests: software engineering technologies, biotechnology, and monitoring of complex biological systems. AuthorID: 1267137, SPIN: 1914-4619, ORCID: 0009-0005-9314-4752, viktorpolyakov1999@mail.ru. 190000, St. Petersburg, st. Bolshaya Morskaya, 67, lit. A.

Статья поступила в редакцию 18.08.2025; одобрена после рецензирования 10.02.2026; принята к публикации 14.05.2026.

The article was submitted 08/18/2025; approved after reviewing 02/10/2026; accepted for publication 05/14/2026.

УДК 519.853.6, 517.958

DOI:10.25729/ESI.2026.42.2.007

## Построение быстрых маршрутов без столкновений в анизотропной среде с динамическими препятствиями

Казаков Александр Леонидович, Лемперт Анна Ананьевна, Чан Туан Вьет

Иркутский национальный исследовательский технический университет,

Россия, Иркутск, *kazakov@icc.ru*

**Аннотация.** В работе рассматривается задача построения маршрутов, минимальных по времени преодоления, для подвижных объектов, в качестве которых могут выступать, например, автономные необитаемые подводные аппараты в водной среде. Основные трудности здесь связаны с наличием пространственно-неоднородных течений, а также статических и движущихся препятствий. Предложен подход, основанный на оптико-геометрической аналогии и принципах Ферма–Гюйгенса. Задача формулируется в терминах обобщенного уравнения эйконала, которое описывает распространение фронта волны в среде с заданным векторным полем скоростей. Такой подход позволяет свести исходную вариационную задачу к дифференциальному уравнению в частных производных и избежать непосредственного перебора возможных траекторий. Поле времени прибытия строится, как решение краевой задачи, а оптимальная траектория восстанавливается движением в направлении антиградиента этого поля. Для численной реализации разработаны два алгоритма. Первый, основанный на методе быстрого марша, вычисляет поле минимального времени от стартовой точки до всех узлов расчетной сетки. Второй алгоритм по этому полю восстанавливает траекторию движения и позволяет получить ее фрагмент, соответствующий заданному временному интервалу. Проведена серия вычислительных экспериментов, включающих четыре сценария разной сложности: прямолинейное течение, два противоположных течения, течение с вихревой зоной и статическими препятствиями, а также сценарий с движущимися препятствиями и вихрем. Во всех случаях алгоритм успешно построил траектории, минимизирующие время движения и обеспечивающие безопасный обход препятствий. В сценарии с динамическими препятствиями продемонстрирована возможность оперативного перестроения маршрута. Проведено сравнение предложенного подхода с методом роевого интеллекта SSA (Salp Swarm Algorithm). Результаты показали, что разработанный алгоритм позволяет находить пути с меньшим временем прохождения, даже если их геометрическая длина превышает длину маршрута, найденного SSA. При этом время расчета траектории достаточно мало, что позволяет осуществлять планирование движения в режиме реального времени.

**Ключевые слова:** задача маршрутизации, динамическая среда, оптико-геометрический подход, уравнение эйконала, алгоритм быстрого марша

**Цитирование:** Казаков А.Л. Построение быстрых маршрутов без столкновений в анизотропной среде с динамическими препятствиями / А.Л. Казаков, А.А. Лемперт, Т.В. Чан // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 87-101. – DOI:10.25729/ESI.2026.42.2.007.

**Введение.** Развитие автономных необитаемых подводных аппаратов (АНПА) открыло новые возможности для мониторинга морской среды, геологических изысканий, инспекции и обслуживания подводной инфраструктуры [1, 2]. Время выполнения миссии является одним из важнейших факторов, определяющих эффективность и энергопотребление АНПА, поэтому построение для них минимальных по времени (быстрых) маршрутов является актуальной проблемой. Отметим, что похожие задачи возникают в области инфраструктурной логистики при размещении объектов коллективного пользования [3, 4].

Кроме того, специфика подводной среды существенно усложняет решение задачи. Во-первых, необходимо учитывать наличие сложных и изменчивых океанических течений [5, 6], которые могут как способствовать движению, так и препятствовать ему, делая кратчайший по расстоянию путь далеко не самым быстрым [7]. Во-вторых, аппарат должен безопасно перемещаться в среде, где присутствуют как статические барьеры (особенности рельефа и запретные для движения зоны), так и динамические объекты [8–10].

Для решения задач навигации и планирования движения в таких условиях существует ряд подходов. Классические методы оптимизации, например, дифференциальная эволюция (DE), демонстрируют эффективность в статической среде [11]. Методы на основе искусственных потенциальных полей (APF) позволяют организовать уклонение от статических препятствий [8]. Планировщики на основе графов, такие как алгоритм D\* и его модификации [12, 13], успешно применяются для перепланирования маршрутов, а RRT\* [14] – для поиска пути в сложных пространствах. В последнее время активно развиваются методы глубокого обучения с подкреплением (DRL), способные вырабатывать сложные стратегии управления путем взаимодействия со средой [15].

Однако в условиях среды, сочетающей стационарные течения и движущиеся объекты, применение этих методов в чистом виде проблематично. Большинство из них либо не учитывают влияния течений на временные затраты, либо требуют слишком много вычислительных ресурсов для оперативного перепланирования маршрута.

В настоящей работе предлагается подход, основанный на оптико-геометрической аналогии [16, 17], которая позволяет свести задачу поиска кратчайшего по времени пути к решению обобщенного уравнения эйконала [18, 19]. Это дает возможность построить глобальное поле времени прибытия от стартовой точки; любая траектория, следующая в направлении, противоположном градиенту этого поля, гарантированно является оптимальной по времени при текущих условиях. Для численного решения уравнения эйконала применяется модификация метода быстрого марша, адаптированная для учета как стационарных течений, так и динамических препятствий. Предложенный алгоритм позволяет не только находить оптимальный маршрут, но и перестраивать его при изменении обстановки за счет локальной актуализации поля времени.

Статья организована следующим образом. В разделе 1 дана математическая постановка задачи. Раздел 2 описывает переход к обобщенному уравнению эйконала и постановку соответствующей краевой задачи. В разделе 3 подробно описаны разработанные вычислительные алгоритмы. Раздел 4 содержит результаты вычислительных экспериментов, иллюстрирующих поведение алгоритма в различных условиях: при наличии течений, вихревых зон и движущихся препятствий, а также сравнение предложенного подхода с методом роевого интеллекта SSA. Заключение подводит итог и намечает направления дальнейших исследований.

**1. Постановка задачи.** В данном разделе строятся модели среды, препятствий и объекта, а также формулируется задача минимизации времени его движения между двумя точками.

**1.1. Модель среды и препятствий.** Рассмотрим область  $\Omega \subseteq R^2$ , в которой движется объект. Выбор двумерной постановки соответствует планированию маршрута на фиксированной глубине, либо планированию маршрута на карте. Переход к трехмерному случаю возможен путем добавления третьей пространственной координаты и не меняет сути предложенного подхода.

Пусть задано стационарное векторное поле скоростей внешней среды  $\vec{w} = (w_1(x, y), w_2(x, y))$ , непрерывное по пространственным координатам и ограниченное  $|\vec{w}| < v$ , где  $v$  – собственная скорость объекта. Это условие гарантирует возможность движения против течения. Среда считается идеальной жидкостью, поскольку вязкостные эффекты пренебрежимо малы по сравнению с переносным движением на масштабах рассматриваемой задачи. Наличие течения делает среду анизотропной для движущегося объекта, поскольку время перемещения зависит от направления.

Множество запретных для движения зон в момент времени  $t$  зададим с помощью индикаторной функции  $h: R^+ \times \Omega \rightarrow \{0,1\}$ . Если точка  $(x, y)$  в момент времени  $t$  непроходима, то  $h(t, x, y) = 0$ , и  $h(t, x, y) = 1$  в противном случае. Тогда множество барьеров определяется, как  $H(t) = \{(x, y) \in \Omega : h(t, x, y) = 0\}$ . Траектория движения не должна пересекать множество  $H(t)$  ни в какой момент времени.

**1.2. Модель объекта и критерий оптимальности.** Объект движется в области  $\Omega$  из точки  $A$  в точку  $B$ , обладая собственной постоянной по модулю скоростью  $v > 0$  относительно среды. Предполагается, что объект является материальной точкой и имеет изотропную тягу – его собственная скорость не зависит от направления движения, а инерционностью разгона и торможения можно пренебречь по сравнению с характерным временем движения. Такое допущение оправдано для небольших аппаратов с маневровыми двигателями, работающими в режиме постоянной тяги. Необходимо построить маршрут с минимально возможным временем прохождения, где  $A, B \in \Omega \setminus H(t), t > 0$ .

**1.3. Математическая формализация.** Пусть  $\Gamma$  – произвольная гладкая кривая, соединяющая точки  $A$  и  $B$ :

$$\Gamma: [0, L] \rightarrow \Omega \setminus H(t), \Gamma(0) = A, \Gamma(L) = B,$$

где  $L$  – полная длина кривой,  $s \in [0, L]$  – натуральный параметр, т.е.  $\Gamma(s)$  определяет точку на кривой на расстоянии  $s$  от ее начала. В каждой точке кривой определен единичный касательный вектор:

$$\vec{\tau}(s) = \frac{1}{\sqrt{1+\Gamma'(s)^2}} \cdot \vec{\tau}_x + \frac{\Gamma'(s)}{\sqrt{1+\Gamma'(s)^2}} \cdot \vec{\tau}_y, \|\vec{\tau}(s)\| = 1.$$

Если объект движется вдоль кривой  $\Gamma$  с путевой скоростью  $v(s)$  (скорость вдоль кривой в неподвижной системе координат), то его собственная скорость относительно среды  $u(s)$  должна удовлетворять векторному уравнению

$$v(s)\vec{\tau}(s) = \vec{u}(s) + \vec{w}(\Gamma(s)), \|\vec{u}(s)\| = v.$$

Выражая  $\vec{u}(s) = v(s)\vec{\tau}(s) - \vec{w}(\Gamma(s))$  и возводя в квадрат, имеем

$$\|v(s)\vec{\tau}(s) - \vec{w}(\Gamma(s))\|^2 = v^2.$$

Раскрыв скобки с учетом  $\|\vec{\tau}(s)\| = 1$ , получаем, что

$$v^2(s) - 2v(s)(\vec{w} \cdot \vec{\tau}) + \|\vec{w}\|^2 = v^2.$$

Это квадратное уравнение относительно  $v(s)$ , его положительный корень, соответствующий движению вперед (второй корень соответствует движению назад), имеет вид

$$v(s) = \vec{w}(\Gamma(s)) \cdot \vec{\tau}(s) + \sqrt{v^2 - \|\vec{w}(\Gamma(s))\|^2 + [\vec{w}(\Gamma(s)) \cdot \vec{\tau}(s)]^2}. \quad (1.1)$$

Предполагается, что дискриминант в (1.1) всюду является положительным, в противном случае попасть из точки  $A$  в точку  $B$  невозможно.

Время движения вдоль кривой  $\Gamma$  равно интегралу от обратной путевой скорости по длине маршрута

$$T(\Gamma) = \int_{\Gamma} dt = \int_0^L \frac{ds}{v(s)}.$$

Таким образом, минимальное время достижения точки  $B$  из точки  $A$  находится, как решение следующей вариационной задачи:

$$T(B) = \min_{\Gamma: A \rightarrow B} \int_0^L \frac{ds}{\vec{w} \cdot \vec{\tau} + \sqrt{v^2 - \|\vec{w}\|^2 + (\vec{w} \cdot \vec{\tau})^2}}. \quad (1.2)$$

**2. О методе решения задач.** Введем функцию  $T(x, y)$ , равную минимальному времени перемещения из фиксированной стартовой точки  $A$  в произвольную точку

$$T(x, y) = \min_{\Gamma: A \rightarrow (x, y)} \int_{\Gamma} \frac{ds}{\vec{w} \cdot \vec{\tau} + \sqrt{v^2 - \|\vec{w}\|^2 + (\vec{w} \cdot \vec{\tau})^2}}.$$

Множества  $\{(x, y) : T(x, y) = \text{const}\}$  образуют семейство изохрон. Вектор-градиент  $\nabla T$  ортогонален изохронам и указывает направление наискорейшего роста функции  $T$ .

Рассмотрим две изохроны  $T(x, y) = t$  и  $T(x, y) = t + dt$ . Пусть расстояние между изохронами вдоль нормали  $\vec{n}$  равно  $dl$ . Тогда приращение  $dT$  при переходе с одной изохроны на другую можно выразить двумя способами: с одной стороны, по определению изохрон, это приращение равно  $dt$ , с другой – из определения градиента имеем, что  $dT = \|\nabla T\| dl$  и тогда получаем следующее выражение для скорости движения фронта между изохронами:

$$v_n = \frac{dl}{dt} = \frac{1}{\|\nabla T\|}.$$

В то же время, абсолютная скорость движения элемента фронта складывается из собственной скорости  $v\vec{n}$ , поскольку фронт распространяется вдоль нормали относительно среды, и переносной скорости среды  $\vec{w}$ :  $\vec{V} = v\vec{n} + \vec{w}$ . Проекция этой скорости на нормаль есть:

$$v_n = \vec{V} \cdot \vec{n} = (v\vec{n} + \vec{w}) \cdot \vec{n} = v + \vec{w} \cdot \vec{n}.$$

Приравняем выражения для  $v_n$ . С учетом того, что единичный вектор нормали выражается через градиент как  $\vec{n} = \nabla T / \|\nabla T\|$ , получаем равенство:

$$\frac{1}{\|\nabla T\|} = v + \vec{w} \cdot \frac{\nabla T}{\|\nabla T\|}.$$

Умножая обе части на  $\|\nabla T\|$ , получаем обобщенное (анизотропное) уравнение эйконала:

$$1 = v\|\nabla T\| + \vec{w} \cdot \nabla T.$$

Таким образом, функция минимального времени  $T(x, y)$  является решением следующей краевой задачи:

$$\begin{cases} v\|\nabla T\| + \vec{w} \cdot \nabla T = 1, x \in \Omega \setminus \{A\}, \\ T(A) = 0, \\ T(x, y) = +\infty, (x, y) \in H(t). \end{cases} \quad (2.1)$$

Если функция  $T(x)$  найдена, то оптимальная траектория из  $B$  в  $A$  получается, как решение системы обыкновенных дифференциальных уравнений в попятном времени:

$$\frac{d}{d\tau} \begin{pmatrix} x \\ y \end{pmatrix} = - \frac{v \frac{\nabla T}{\|\nabla T\|} + \vec{w}}{\left\| v \frac{\nabla T}{\|\nabla T\|} + \vec{w} \right\|}, \quad x(0) = x_B, y(0) = y_B, \quad (2.2)$$

где  $\tau$  пробегает значения от 0 до  $T(x_B, y_B)$ . В результате получается искомый оптимальный маршрут – кривая, соединяющая точки  $A$  и  $B$ .

**3. Вычислительные алгоритмы.** Для численного решения задачи (2.1) введем равномерную прямоугольную сетку  $X_h \subset \Omega$  с шагом  $h$  по обеим координатам. Рассмотрим два узла сетки  $q = (x_q, y_q)$  и  $m = (x_m, y_m)$ . Обозначим  $\Delta x = x_m - x_q$ ,  $\Delta y = y_m - y_q$ .

Пусть объект движется из  $q$  в  $m$ , выбирая направление  $\theta$ . Вектор собственной скорости относительно среды равен  $(v \cos \theta, v \sin \theta)$ . За время  $t$  объект должен пройти путь  $(\Delta x, \Delta y)$  с абсолютной скоростью, равной сумме собственной скорости и скорости течения:

$$\begin{cases} \Delta x = [v \cos \theta + w_1(q)]t, \\ \Delta y = [v \sin \theta + w_2(q)]t, \end{cases} \quad (3.1)$$

где  $w_1(q), w_2(q)$  – компоненты поля  $\vec{w}$  в точке  $q$ .

Выразим из (3.1) проекции собственной скорости, возведем в квадрат, и, используя универсальное тригонометрическое тождество  $\sin^2 \theta + \cos^2 \theta = 1$ , получаем:

$$(w_1^2 + w_2^2 - v^2)t^2 - 2(w_1\Delta x + w_2\Delta y)t + (\Delta x^2 + \Delta y^2) = 0. \quad (3.2)$$

Наименьший положительный корень уравнения (3.2) дает минимальное время  $t_{qm}$ , за которое объект может переместиться из  $q$  в  $m$ . Если уравнение не имеет положительных корней, переход невозможен.

**Алгоритм 1: Построение скалярного поля времен**

Шаг 0 (инициализация): Для каждого узла  $p(x_p, y_p) \in X_h$  устанавливаются время прихода волны  $T_p = +\infty$  и предшествующий узел  $S_p = \emptyset$ . Для начальной точки  $A$  полагается  $T_A = 0$ . Вводятся шаг по времени  $\Delta t$ , с которым проверяется положение препятствий, и счетчик шагов по времени  $N = 0$ . Создаются приоритетная очередь  $Q$  и список отложенных узлов  $L, Q = \{A\}, L = \emptyset$ .

Шаг 1: Если  $Q \neq \emptyset$ , для первого элемента  $q \in Q$  определяется множество  $M$ , включающее  $(2k + 1)^2 - 1, k \geq 1$  точек, соседних по сетке с точкой  $q(x_q, y_q)$ :

$$M = \{m(x_q + \delta_x, y_q + \delta_y) : \delta_x = ih, \delta_y = jh, i, j = -k, \dots, k\}.$$

Шаг 2: Для каждого  $m \in M$  вычисляется время перехода  $t_{qm}$ , как наименьший положительный корень уравнения (3.2). Если положительного корня нет, то  $t_{qm} = +\infty$ . Подсчитывается  $T'_m = T_q + t_{qm}$ . Если  $T_q = +\infty$  или  $t_{qm} = +\infty$ , то  $T'_m = +\infty$ .

Шаг 3: Если  $m \notin H(T'_m)$  и  $T'_m < T_m$ , то  $T_m = T'_m, S_m = \{q\}$ .

Шаг 4: Если  $T_m \leq t_0 + (N + 1)\Delta t$ , то  $Q = Q \cup \{m\}$  (волна достигла узла в текущем временном слое), иначе  $L = L \cup \{m\}$ .

Шаги 2 - 4 выполняются независимо для всех  $m \in M$ .

Шаг 5: Точка  $q$  исключается из очереди  $Q = Q \setminus \{q\}$ . Если  $Q = \emptyset$ , переход к шагу 6, иначе переход к шагу 1.

Шаг 6: Если  $Q = \emptyset$ , выполняется цикл проверки отложенных узлов:  $Q = \emptyset$  и  $L \neq \emptyset$ , то увеличивается счетчик времени:  $N = N + 1$ , формируется множество

$U = \{p \in L : T_p \leq t_0 + (N+1)\Delta t\}$  и элементы множества  $U$  переносятся из  $L$  в  $Q : Q = Q \cup U$ ,  $L = L \setminus U$ .

Шаг 7: Если  $Q \neq \emptyset$ , переход к шагу 1. Если  $Q = \emptyset$  и  $L = \emptyset$ , алгоритм завершается.

После завершения алгоритма для каждого узла сетки  $p \in X_n$  известно время прихода волны  $T_p$  из стартовой точки  $A$  и узел-предшественник  $S_p$ .

### Алгоритм 2: Построение маршрута (RCA)

Алгоритм позволяет найти самый быстрый маршрут из точки  $A$  в точку  $B$ ,  $A, B \in \Omega \setminus H(t)$  и определить, какая его часть будет пройдена за заданный интервал времени  $\Delta t$ .

Шаг 0 (инициализация): Пусть  $L(A, B)$  – список точек маршрута из  $A$  в  $B$ . Полагается  $L(A, B) = \{B\}$ . Вводится параметр  $type$ , определяющий режим построения маршрута. Если  $type = 0$ , то строится полный маршрут из точки  $A$  в точку  $B$ ,  $type = 1$  – определяется часть маршрута, проходимая за время  $\Delta t$ .

Шаг 1: Для точки  $A$  строится скалярное поле времени по алгоритму 1.

Шаг 2: Если  $T_B = +\infty$ , алгоритм завершается: маршрут не существует.

Шаг 3: Для последней точки  $p$  в списке  $L(A, B)$  определяется ее предшественник  $S_p$ , который добавляется в конец списка:  $L(A, B) = L(A, B) \cup \{S_p\}$ .

Шаг 4: Если  $S_p = A$ , то переход к шагу 5. В противном случае переход к шагу 3.

Шаг 5: Элементы списка  $L(A, B)$  упорядочиваются в обратном порядке, так чтобы начальной точкой стала  $A$ , а конечной –  $B$ .

Шаг 6: Если  $type = 0$ , то алгоритм завершается возвратом списка  $L(A, B)$ . В противном случае переход к шагу 7.

Шаг 7: В маршруте  $L(A, B)$  находится точка  $p^* \in L(A, B)$ , для которой время  $T_{p^*}$  удовлетворяет условию  $T_{p^*} = \max \{T_p : p \in L(A, B), T_p \leq t_0 + \Delta t\}$ . Эта точка является наиболее удаленной точкой на маршруте, которую объект может достичь за время  $\Delta t$ .

Шаг 8: Находится подсписок  $L(A, p^*) \subseteq L(A, B)$ , содержащий точки от  $A$  до  $p^*$ . Алгоритм завершается.

Алгоритм возвращает список точек  $L(A, p^*)$ , представляющий собой маршрут движения объекта из начальной точки  $A$  в точку  $p^*$ , достижимую за время  $\Delta t$ . Если  $p^* = A$ , то объект не может сдвинуться с начальной точки за отведенное время, а если  $p^* = B$ , то объект успевает достичь конечной точки.

**4. Вычислительный эксперимент.** Все алгоритмы реализованы на языке C# в пакете Visual Studio 2022, вычисления производились на персональном компьютере с конфигурацией Intel (R) Core(TM) i5-3337U (частота 1.8 GHz, 4 CPUs, 6 GB RAM) и операционной системой Windows 10. Для демонстрации возможностей алгоритма выбраны четыре сценария с усложняющимися условиями: от однородного течения до комбинации вихря, статических и движущихся препятствий. Параметры среды (размеры области, скорости течений, расположение препятствий) и характеристики объекта (собственная скорость) подобраны так, чтобы наглядно показать особенности оптимальных траекторий, в частности, использование попутных течений, обход препятствий, перепланирование при движущихся барьерах. Численные значения не привязаны к конкретному натурному

эксперименту, но соответствуют порядкам величин, характерным для подводных аппаратов в прибрежных зонах. Для сравнения эффективности предложенного алгоритма RCA был использован алгоритм SSA (Salp Swarm Algorithm) [20], поскольку в [21, 22] показано, что он демонстрирует лучшие результаты по сравнению с другими эвристическими алгоритмами (PSO, WOA, GWO и MVO).


*Пример 1.* Рассматривается задача движения объекта со скоростью  $v = 0.2$  (м/с) из точки  $S(20;20)$  в точку  $F(90;90)$  в среде размером  $100 \times 100$  (м) без препятствий  $H(t) = \emptyset$ . Поле скоростей среды описывается следующим образом:

$$\vec{w}(w_1, w_2) = \begin{cases} \omega \vec{i} + 0 \vec{j}, & y \in [30; 70], \\ 0 \vec{i} + 0 \vec{j}, & y \notin [30; 70], \end{cases} \text{ где } \omega > 0.$$

В полосе  $y \in [30; 70]$  имеет место течение, направленное вдоль оси  $Ox$  со скоростью  $\omega$  (м/с).

Маршрут строится с помощью описанных выше алгоритмов со следующими параметрами: шаг сетки  $h = 0.2$  (м), временной шаг  $\Delta t = 1$  (с), размер окрестности  $k = 3$ ,  $type = 0$ . Результаты расчетов представлены на рисунке 1.

При  $\omega = 0.3$  (м/с) объект движется по прямой от  $S$  до точки входа в поток  $S_1(20;30)$ , затем использует попутное течение и перемещается в точку  $S_2(90;70.4)$ , после чего, покинув зону течения, следует прямо к цели  $F$ . Время движения составляет  $t_{0.3} = 356.9$  (с), длина маршрута –  $l_{0.3} = 110.42$  (м). Маршрут показан жирной линией на рисунке 1а.



**Рис. 1.** Маршруты движения объекта в примере 1

При увеличении скорости потока до  $\omega = 0.4$  (м/с) маршрут объекта еще сильнее отклоняется от прямой, соединяющей  $S$  и  $F$  (см. рис. 1б). Такое поведение объясняется стремлением алгоритма максимально эффективно использовать течение для минимизации общего времени в пути. Время движения –  $t_{0.4} = 357.8$  (с), длина маршрута –  $l_{0.4} = 120.67$  (м).

Результаты сравнения с алгоритмом SSA представлены в таблице 1. При  $\omega = 0.3$  (м/с), наилучший найденный им маршрут длиной 104.32 (м) имеет вид ломаной из пяти отрезков с вершинами  $P_0(20;20)$ ;  $P_1(20.96; 30.05)$ ;  $P_2(30.21; 35.70)$ ;  $P_3(81.56; 70.21)$ ;  $P_4(90; 90)$ , время движения составляет 359.75 (с). Маршрут показан тонкой линией на рисунке 1а.

**Таблица 1.** Результаты эксперимента 1


Алгоритм	Длина маршрута	Время движения
RCA	110.42 (м)	356.9 (с)
SSA	104.32 (м)	359.75 (с)

*Пример 2.* Рассматривается область размером  $100 \times 100$  (м) без препятствий ( $H(t) = \emptyset$ ). Скорость течения задается следующим образом:

$$\vec{w}(w_1, w_2) = \begin{cases} 0\vec{i} + 0\vec{j}, & x \in [0; 20] \cup [40; 60] \cup [80; 100], \\ 0.3\vec{i} + 0\vec{j}, & x \in (20; 40), \\ 0\vec{i} - 0.3\vec{j}, & x \in (60; 80), \end{cases}$$

Объект движется из точки  $S(10; 30)$  в точку  $F(90; 30)$  с собственной скоростью  $v = 0.2$  (м/с).

Как видно из описания, в области имеются два противоположно направленных течения: одно – в положительном направлении оси  $Ox$  (поток 1), другое – в отрицательном (поток 2). Полученная траектория показана на рисунке 2а. Объект движется по прямой, чтобы войти в поток 1 в ближайшей точке  $S_1(20.2; 30)$ , следует по течению до точки  $S_2(40; 59.4)$ , затем по кратчайшему пути пересекает область без течения и входит в поток 2 в точке  $S_3(60; 59.4)$ , движется по нему до точки  $S_4(80; 30)$  и, наконец, достигает цели  $F$  по кратчайшему пути. Время движения составляет 400 (с), длина маршрута 112.2 (м).



**Рис. 2.** Маршруты движения объекта в примере 2

Если увеличить скорость обоих потоков до 0.6 (м/с), траектория удлинится, но время движения остается равным 400 (с) (см. рис. 2б).

Результаты сравнения с алгоритмом SSA представлены в таблице 2. Можно видеть, что в этом случае RCA показал результаты лучше, чем SSA, как по длине маршрута, так и по времени движения.

**Таблица 2.** Результаты эксперимента 2

Алгоритм	Длина маршрута	Время движения
RCA	112.2 (м)	400 (с)
SSA	126 (м)	480 (с)

*Пример 3.* Рассматривается задача поиска маршрута из точки  $S(10;10)$  до  $F(90;90)$  в области размером  $100 \times 100$  (м), содержащей неподвижные препятствия. В полосе  $x \in [30, 70]$  присутствует течение, направленное вдоль оси  $Ox$  и имеющее скорость  $0.3$  (м/с). Кроме того, в области имеется вихревая зона, имеющая форму круга с центром в точке  $O(50,50)$  и радиусом  $r = 12$  (м). Внутри этой зоны вращение происходит по часовой стрелке, скорость течения направлена по касательной к окружности, постоянна по модулю и равна  $0.5$  (м/с). Таким образом, поле скорости задается следующим образом:

$$\vec{w}(w_1, w_2) = \begin{cases} 0\vec{i} + 0\vec{j}, & y \in [0;30) \cup (70;100] \cup (50;50), \\ 0.3\vec{i} + 0\vec{j}, & y \in [30;70], d > 12, \\ a\vec{i} + b\vec{j}, & y \in [30;70], 0 < d \leq 12, \end{cases}$$


где  $d = \sqrt{(x-50)^2 + (y-50)^2}$ ,  $a = -0.5(y-50)d^{-1}$ ,  $b = 0.5(x-50)d^{-1}$ .

В области также расположены два прямоугольных препятствия

$$H_1(t) = \{(x, y) : 0 \leq x \leq 15, 15 \leq y \leq 25\}, \quad H_2(t) = \{(x, y) : 85 \leq x \leq 100, 75 \leq y \leq 85\}.$$

Собственная скорость объекта составляет  $0.2$  (м/с).

Построенный маршрут показан на рисунке 3. На первом этапе (0-114.4 с) объект движется из стартовой точки  $S(10;10)$  к нижней границе области течения, огибает препятствие  $H_1$ , проходя через  $S_1(15.2; 15.2)$ , и достигает точки входа в поток в  $S_2(20.1; 30)$ . На втором этапе (114.4-277.1 с) объект входит в область горизонтального течения, движется в потоке в сторону вихревой зоны и входит в нее в  $S_3(42.1; 41)$ . В вихре скорость направлена по касательной к окружности, поэтому траектория искривляется. Двигаясь внутри вихря, объект достигает точки  $S_4(50.6; 61.4)$ , где направление вихревого течения максимально отклоняет траекторию от прямолинейной. В точке  $S_5(53.8; 61.4)$  объект покидает вихревую зону и выходит в область чистого горизонтального течения, после чего продолжает движение в потоке, покидая его в точке  $S_6(79.6; 70)$ . На заключительном этапе (277.1-392.1 с) огибает препятствие  $H_2$ , проходя через точку  $S_7(84.9; 85.1)$ , и достигает целевой точки. Общее время движения составляет  $392.1$  с.



**Рис. 3.** Маршрут объекта в пример 3

Отметим, что прямолинейное движение в неподвижной среде без препятствий потребовало бы 565.7 (с). Выигрыш во времени достигается за счет использования течения и вихря, несмотря на необходимость обхода препятствий.

*Пример 4.* Рассматривается область с двумя противоположно направленными вертикальными течениями. Скорость каждого из потоков составляет 0.1 (м/с). В центре области  $O(50;50)$  расположена вихревая зона – круг радиуса  $r = 10$  (м). Внутри этой зоны вращение происходит по часовой стрелке, вектор скорости направлен по касательной к окружности, а модуль возрастает при приближении к центру (суперпозиция вращения и радиального сноса к центру). Таким образом, поле скорости задается следующим образом:

$$\vec{w}(w_1, w_2) = \begin{cases} 0\vec{i} + 0.1\vec{j}, & x \in [0;50], d > 10, \\ 0\vec{i} - 0.1\vec{j}, & x \in [50;100], d > 10, \\ a\vec{i} + b\vec{j}, & 0 < d \leq 10, \\ 0\vec{i} + 0\vec{j}, & d = 0, \end{cases}$$

где  $d = \sqrt{(x-50)^2 + (y-50)^2}$ ,  $a = 0.3(y-50)d^{-1} - (x-50)d^{-1}$ ,  $b = -0.3(x-50)d^{-1} - (y-50)d^{-1}$ .

В области имеются три препятствия: статический барьер  $H_1$ , представляющий собой квадрат со стороной 30 (м), барьер  $H_2$  – квадрат со стороной 20 (м), движущийся слева направо со скоростью 0.3 (м/с), и  $H_3$  – прямоугольник  $10 \times 24$  (м), движущийся справа налево со скоростью 0.07 (м/с). Тогда множество  $H(t)$  имеет вид

$$H(t) = H_1(t) \cup H_2(t) \cup H_3(t), \quad \text{где } H_1(t) = \{(x, y) : 0 \leq x \leq 20, 30 \leq y \leq 50\},$$

$$H_2(t) = \{(x, y) : 0 \leq x - 0.3t \leq 10, 10 \leq y \leq 20\}, H_3(t) = \{(x, y) : 75 \leq x + 0.07t \leq 99, 75 \leq y \leq 85\}.$$

Объект движется из точки  $S(0;0)$  в точку  $F(99;99)$  с собственной скоростью 0.2 (м/с).

Для решения задачи Алгоритм RCA применяется многократно: при каждом запуске в режиме  $type = 1$  строится участок маршрута, который объект проходит за время  $\Delta t = 1.667$  (с). После каждого запуска начальная точка сдвигается в текущее положение объекта.

На первом интервале времени  $[0;16.67]$  (с) объект движется по прямой и достигает точки  $S_1(3;2.67)$  (рис. 4а). На интервале  $[16.67;46.67]$  (с) препятствие  $H_2$  смещается вправо, и объект, отклоняясь от прямолинейного курса, чтобы избежать столкновения, достигает точки  $S_2(6.19;8.19)$  (рис. 4б). На интервале  $[46.67;145]$  (с) объект движется в области, свободной от препятствий, и направляется к точке  $S_3(24;26.19)$ , избегая попадания в центр вихревой зоны (рис. 4в). На интервале  $[145;235]$  (с) препятствие  $H_3$  смещается влево и блокирует прямой путь. Объект мог бы обойти его справа от вихря, но тогда он двигался бы против течения, что увеличило бы время. Поэтому выбирается траектория слева от вихря, проходящая вблизи препятствия  $H_1$  и использующая попутное течение. Объект достигает точки  $S_4(24.33;52.97)$  (рис. 4г).

На заключительном интервале  $[235;721.67]$  (с) объект движется вдоль правого течения, затем перпендикулярно ему, к цели. Полное время движения  $T^* = 721.67$  (с) (рис. 5).

Таким образом, во всех сценариях алгоритм RCA находит маршруты с меньшим временем движения по сравнению с SSA там, где сравнение проводилось (выигрыш до 20% в примере 2). В примере 3 рациональное использование течений позволяет сократить время на 30% по сравнению с прямолинейным движением в неподвижной среде. Геометрическая длина траектории RCA может быть больше, чем у SSA (пример 1), что является «платой» за

использование попутных течений. Поскольку собственная скорость объекта постоянна, энергозатраты пропорциональны времени движения, поэтому RCA также минимизирует энергопотребление. В примере 4 продемонстрирована возможность оперативного перепланирования маршрута при движущихся препятствиях, что подтверждает пригодность алгоритма для систем реального времени.

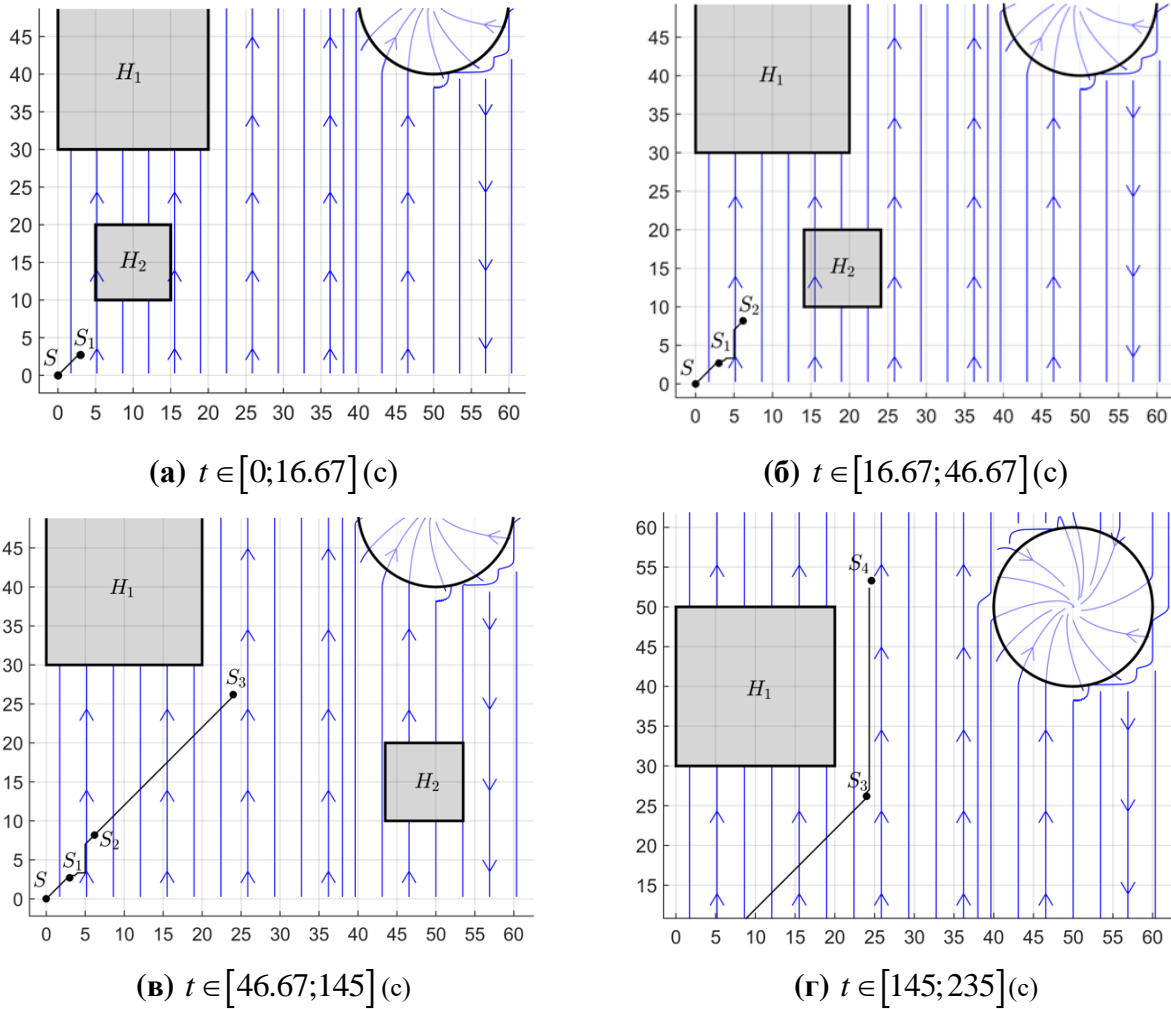


Рис. 4. Маршрут объекта на различных промежутках времени в примере 4




Рис. 5. Маршрут объекта в примере 4

**Заключение.** В работе рассмотрена задача поиска минимальных по времени маршрутов в динамической водной среде с учетом течений и движущихся препятствий. Предложен новый подход, основанный на численном решении уравнения эйконала и модифицированном методе быстрого марша. Разработаны два базовых алгоритма.

На различных сценариях показано, что разработанный алгоритм не только строит траектории, минимизирующие время движения, но и обеспечивает безопасный обход статических и динамических препятствий за счет оперативной перепланировки пути. Сравнение с методом SSA подтверждает преимущество предложенного подхода по основному критерию – времени в пути. При этом время расчета траектории достаточно мало, что позволяет осуществлять планирование движения в режиме реального времени.

В реальных условиях данные о течениях и препятствиях поступают от навигационных систем с определенной погрешностью. Предложенный алгоритм может работать в режиме повторного планирования: по мере получения уточненной информации поле времени пересчитывается локально. Анализ чувствительности к ошибкам входных данных является предметом дальнейших исследований.

Кроме того, дальнейшие исследования могут быть направлены на учет нестационарных полей течений, а также на адаптацию метода для работы с более сложными моделями движения объекта, учитывающими, в том числе, парусность – зависимость собственной скорости от ориентации.

#### Список источников

1. Liu L., Sun M., Zhao E. et al. Three-dimensional dynamic trajectory planning for autonomous underwater robots under the PPO-IIFDS framework. *Journal of Marine Science and Engineering*, 2025, vol. 13, no. 3, p. 445, DOI: 10.3390/jmse13030445.
2. Paull L., Saeedi S., Seto M., Li H. AUV navigation and localization: A review. *IEEE Journal of Oceanic Engineering*, 2014, vol. 39, no. 1, pp. 131-149. DOI: 10.1109/JOE.2013.2278891.
3. Бухаров Д.С. Программная система «Виголт» для решения задач оптимизации, возникающих в транспортной логистике / Д.С. Бухаров, А.Л. Казаков // *Вычислительные методы и программирование*, 2012. – Т. 13. – № 3. – С. 65-74.
4. Lempert A.A., Kazakov A.L., Bukharov D.S. Mathematical model and program system for solving a problem of logistic objects placement. *Automation and Remote Control*, 2015, vol. 76, no. 8, pp. 1463-1470.
5. Doshi M.M., Bhabra M.S., Lermusiaux P.F.J. Energy–time optimal path planning in dynamic flows: theory and schemes. *Computer Methods in Applied Mechanics and Engineering*, 2023, vol. 405, p. 115865, DOI: 10.1016/j.cma.2022.115865.
6. Chen M., Zhu D. Optimal time-consuming path planning for autonomous underwater vehicles based on a dynamic neural network model in ocean current environments. *IEEE Transactions on Vehicular Technology*, 2020, vol. 69, pp. 14401-14412, DOI: 10.1109/TVT.2020.3034628.
7. Zhu D., Yang S.X. Path planning method for unmanned underwater vehicles eliminating effect of currents based on artificial potential field. *Journal of Navigation*, 2021, vol. 74, pp. 955-967, DOI: 10.1017/S0373463321000345.
8. Xanthidis M., Karapetyan N., Damron H. et al. Navigation in the presence of obstacles for an agile autonomous underwater vehicle. *Proceedings of the IEEE International Conference on Robotics and Automation*, 2020, pp. 892-899, DOI:10.48550/arXiv.1903.11750.
9. Yang H., Mahmoudian N. Effective underwater glider path planning in dynamic 3D environments using multi-point potential fields. *arXiv preprint*, arXiv:2403.08163, 2024, DOI: 10.48550/arXiv.2403.08163.
10. Zhu D., Cheng C., Sun B. An integrated AUV path planning algorithm with ocean current and dynamic obstacles. *International Journal of Robotics and Automation*, 2016, vol. 31, pp. 382-389, DOI: 10.2316/Journal.206.2016.5.206-4570.
11. Mahmoud Zadeh S., Powers D.M.W., Yazdani A. et al. Efficient AUV path planning in time-variant underwater environment using differential evolution algorithm. *Journal of Marine Science and Application*, 2018, vol. 17, no. 4, pp. 585-591, DOI: 10.1007/s11804-018-0034-4.
12. Raheem F.A., Hameed U.I. Path planning algorithm using D\* heuristic method based on PSO in dynamic environment. *American Scientific Research Journal for Engineering, Technology and Sciences*, 2018, vol. 490, no. 1, pp. 257-271.

13. Jin P., Li W., Zhan J., Shan C. 3D Obstacle Avoidance Path Planning Algorithm and Software Design for UUV Based on Improved D\* Lite-APF. *Journal of Marine Science and Engineering*, 2026, vol. 14, no. 4, p. 373. DOI: 10.3390/jmse14040373.
14. Gao J., Geng X., Zhang Y. et al. Underwater vehicle path planning based on bidirectional path and cached random tree star algorithm. *Applied Sciences*, 2024, vol. 14, p. 947, DOI: 10.3390/app14020947.
15. Chu Z., Wang F., Lei T. et al. Path planning based on deep reinforcement learning for autonomous underwater vehicles under ocean current disturbance. *IEEE Transactions on Intelligent Vehicles*, 2022, vol. 8, no. 1, pp. 108–120, DOI: 10.1109/TIV.2022.3153352.
16. Казаков А.Л. Об одном подходе к решению задач оптимизации, возникающих в транспортной логистике / А.Л. Казаков, А.А. Лемперт // *Автоматика и телемеханика*, 2011. – № 7. – С. 50–57. – DOI: 10.1134/S0005117911070071.
17. Казаков А.Л. Об одном численном методе решения некоторых задач оптимизации, возникающих в транспортной логистике / А.Л. Казаков, А.А. Лемперт, Д.С. Бухаров // *Вестник Иркутского государственного технического университета*, 2011. – № 6 (53). – С. 6–12.
18. Казаков А.Л. О построении маршрутов в динамической среде с использованием решений уравнения эйконала / А.Л. Казаков, А.А. Лемперт // *Известия Института математики и информатики Удмуртского государственного университета*, 2021. – Т. 82. – № 6. – С. 3–13. – DOI: 10.35634/2226-3594-2021-58-04.
19. Боровских А.В. Двумерное уравнение эйконала // *Сибирский математический журнал*, 2006. – Т. 47. – № 5. – С. 993–1018. – DOI:10.1007/s11202-006-0091-9.
20. Mirjalili S., Gandomi A.H., Mirjalili S.Z. et al. Salp swarm algorithm: a bio-inspired optimizer for engineering design problems. *Advances in Engineering Software*, 2017, vol. 114, pp. 163–191, DOI:10.1016/j.advengsoft.2017.07.002.
21. Guo X., Zhao D., Fan T. et al., Autonomous underwater vehicle path planning based on improved salp swarm algorithm. *Journal of Marine Science and Engineering*, 2024, vol. 12, no 8, p. 1446. DOI:10.3390/jmse12081446.
22. Joshi M., Kalita K., Jangir P. et al. A conceptual comparison of dragonfly algorithm variants for CEC-2021 global optimization problems. *Arabian Journal for Science and Engineering*, 2023, vol. 48, pp. 1563–1593, DOI: 10.1007/s13369-022-06880-9.

**Казаков Александр Леонидович.** Докт. физ.- мат. наук, профессор Иркутского национального исследовательского технического университета. AuthorID: 14911, SPIN: 8101-9424, ORCID: 0000-0002-3047-1650. kazakov@icc.ru, 664033, Россия, Иркутск.

**Лемперт Анна Ананьевна.** Канд. физ.- мат. наук, доцент Иркутского национального исследовательского технического университета, AuthorID: 128334, SPIN: 2774-4751, ORCID: 0000-0001-9562-7903. lempert@icc.ru, 664033, Россия, Иркутск.

**Чан Туан Вьет.** Аспирант Иркутского национального исследовательского технического университета, AuthorID: 1345480, SPIN: 7043-1530, ORCID: 0009-0008-1048-1473. mr.ttviet.1986@gmail.com, 664033, Россия, Иркутск.

UDC 519.853.6, 517.958

DOI:10.25729/ESI.2026.42.2.007

## Time-optimal collision-free path planning in anisotropic environments with moving obstacles

Aleksandr L. Kazakov, Anna A. Lempert, Viet T. Tran

Irkutsk National Research Technical University, Russia, Irkutsk, kazakov@icc.ru

**Abstract.** This paper addresses the problem of constructing time-optimal paths for a moving vehicle, specifically an autonomous underwater vehicle operating in an aquatic environment. The main difficulties stem from spatially non-uniform currents and the presence of both static and moving obstacles. We propose an approach based on the optical-geometric analogy and the Fermat–Huygens principle. The problem is formulated as a

generalized eikonal equation that describes the propagation of a wavefront in a medium with a prescribed velocity vector field. This formulation reduces the original variational problem to a partial differential equation, eliminating the need for an exhaustive search over candidate trajectories. The arrival time field is obtained as the solution to a boundary value problem, and the optimal path is recovered by moving against the gradient of this field. We develop two algorithms for numerical implementation. The first, based on the fast marching method, calculates the minimal time field from the start point to all nodes of a computational grid. The second algorithm reconstructs the optimal trajectory from this field and extracts the section corresponding to a specified time horizon. We perform a series of numerical experiments on four test scenarios of increasing complexity: a uniform flow, two opposing flows, a flow with a vortex and static obstacles, and a scenario that combines moving obstacles with a vortex. In all cases, the algorithm constructs time-optimal paths successfully while ensuring safe obstacle avoidance. The scenario with dynamic obstacles demonstrated the ability to adjust the route dynamically. We compared the proposed approach with the Salp Swarm Algorithm (SSA). The results show that our algorithm finds paths with shorter travel times, even when their geometrical length exceeds that of the routes produced by SSA. Moreover, the computation time is sufficiently low to allow real-time path planning.

**Keywords:** routing problem, dynamic environment, optical-geometric approach, eikonal equation, fast marching method

## References

1. Liu L., Sun M., Zhao E. et al. Three-dimensional dynamic trajectory planning for autonomous underwater robots under the PPO-IIFDS framework. *Journal of Marine Science and Engineering*, 2025, vol. 13, no. 3, p. 445, DOI: 10.3390/jmse13030445.
2. Paull L., Saeedi S., Seto M., Li H. AUV navigation and localization: A review. *IEEE Journal of Oceanic Engineering*, 2014, vol. 39, no. 1, pp. 131-149. DOI: 10.1109/JOE.2013.2278891.
3. Bukharov D.S., Kazakov A.L. Programmaya sistema "Vigolt" dlya resheniya zadach optimizatsii, vznikayushchikh v transportnoy logistike [The Vigolt software system for solving optimization problems arising in transport logistics]. *Vychislitel'nyye metody i programmirovaniye [Computational Methods and Programming]*, 2012, vol. 13, no. 3, pp. 65-74.
4. Lempert A.A., Kazakov A.L., Bukharov D.S. Mathematical model and program system for solving a problem of logistic objects placement. *Automation and Remote Control*, 2015, vol. 76, no. 8, pp. 1463-1470.
5. Doshi M.M., Bhabra M.S., Lermusiaux P.F.J. Energy-time optimal path planning in dynamic flows: theory and schemes. *Computer Methods in Applied Mechanics and Engineering*, 2023, vol. 405, p. 115865, DOI: 10.1016/j.cma.2022.115865.
6. Chen M., Zhu D. Optimal time-consuming path planning for autonomous underwater vehicles based on a dynamic neural network model in ocean current environments. *IEEE Transactions on Vehicular Technology*, 2020, vol. 69, pp. 14401-14412, DOI: 10.1109/TVT.2020.3034628.
7. Zhu D., Yang S.X. Path planning method for unmanned underwater vehicles eliminating effect of currents based on artificial potential field. *Journal of Navigation*, 2021, vol. 74, pp. 955-967, DOI: 10.1017/S0373463321000345.
8. Xanthidis M., Karapetyan N., Damron H. et al. Navigation in the presence of obstacles for an agile autonomous underwater vehicle. *Proceedings of the IEEE International Conference on Robotics and Automation*, 2020, pp. 892-899, DOI:10.48550/arXiv.1903.11750.
9. Yang H., Mahmoudian N. Effective underwater glider path planning in dynamic 3D environments using multi-point potential fields. *arXiv preprint*, arXiv:2403.08163, 2024, DOI: 10.48550/arXiv.2403.08163.
10. Zhu D., Cheng C., Sun B. An integrated AUV path planning algorithm with ocean current and dynamic obstacles. *International Journal of Robotics and Automation*, 2016, vol. 31, pp. 382-389, DOI: 10.2316/Journal.206.2016.5.206-4570.
11. Mahmoud Zadeh S., Powers D.M.W., Yazdani A. et al. Efficient AUV path planning in time-variant underwater environment using differential evolution algorithm. *Journal of Marine Science and Application*, 2018, vol. 17, no. 4, pp. 585-591, DOI: 10.1007/s11804-018-0034-4.
12. Raheem F.A., Hameed U.I. Path planning algorithm using D\* heuristic method based on PSO in dynamic environment. *American Scientific Research Journal for Engineering, Technology and Sciences*, 2018, vol. 490, no. 1, pp. 257-271.
13. Jin P., Li W., Zhan J., Shan C. 3D Obstacle Avoidance Path Planning Algorithm and Software Design for UUV Based on Improved D\* Lite-APF. *Journal of Marine Science and Engineering*, 2026, vol. 14, no. 4, p. 373. DOI: 10.3390/jmse14040373.

14. Gao J., Geng X., Zhang Y. et al. Underwater vehicle path planning based on bidirectional path and cached random tree star algorithm. *Applied Sciences*, 2024, vol. 14, p. 947, DOI: 10.3390/app14020947.
15. Chu Z., Wang F., Lei T. et al. Path planning based on deep reinforcement learning for autonomous underwater vehicles under ocean current disturbance. *IEEE Transactions on Intelligent Vehicles*, 2022, vol. 8, no. 1, pp. 108-120, DOI: 10.1109/TIV.2022.3153352.
16. Kazakov A.L., Lempert A.A. Ob odnom podkhode k resheniyu zadach optimizatsii, vznikayushchikh v transportnoy logistike [On one approach to solving optimization problems arising in transport logistics]. *Avtomatika i telemekhanika [Automation and Remote Control]*, 2011, no. 7, pp. 50–57, DOI: 10.1134/S0005117911070071.
17. Kazakov A.L., Lempert A.A., Bukharov D.S. Ob odnom chislennom metode resheniya nekotorykh zadach optimizatsii, vznikayushchikh v transportnoy logistike [On one numerical method for solving some optimization problems arising in transport logistics]. *Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta [Bulletin of Irkutsk State Technical University]*, 2011, no. 6 (53), pp. 6-12.
18. Kazakov A.L., Lempert A.A. O postroyenii marshrutov v dinamicheskoy srede s ispol'zovaniyem resheniy uravneniya eikonala [On path planning in a dynamic environment using solutions of the eikonal equation]. *Izvestiya Instituta matematiki i informatiki Udmurtskogo gosudarstvennogo universiteta [Proceedings of the Institute of Mathematics and Informatics of Udmurt State University]*, 2021, vol. 82, no. 6, pp. 3–13, DOI: DOI: 10.35634/2226-3594-2021-58-04.
19. Borovskikh A.V. Dvumernoye uravneniye eikonala [Two-dimensional eikonal equation]. *Sibirskiy matematicheskiy zhurnal [Siberian Mathematical Journal]*, 2006, vol. 47, no. 5, pp. 993–1018, DOI: 10.1007/s11202-006-0091-9.
20. Mirjalili S., Gandomi A.H., Mirjalili S.Z. et al. Salp swarm algorithm: a bio-inspired optimizer for engineering design problems. *Advances in Engineering Software*, 2017, vol. 114, pp. 163-191, DOI:10.1016/j.advengsoft.2017.07.002.
21. Guo X., Zhao D., Fan T. et al., Autonomous underwater vehicle path planning based on improved salp swarm algorithm. *Journal of Marine Science and Engineering*, 2024, vol. 12, no 8, p. 1446. DOI:10.3390/jmse12081446.
22. Joshi M., Kalita K., Jangir P. et al. A conceptual comparison of dragonfly algorithm variants for CEC-2021 global optimization problems. *Arabian Journal for Science and Engineering*, 2023, vol. 48, pp. 1563-1593, DOI: 10.1007/s13369-022-06880-9.

**Kazakov Aleksandr Leonidovich.** *Dr. Phys.-Math. Sci., professor at Irkutsk National Research State Technical University, AuthorID: 14911, SPIN: 8101-9424, ORCID: 0000-0002-3047-1650. kazakov@icc.ru, 664033, Russia, Irkutsk.*

**Lempert Anna Ananievna.** *Cand. Phys.-Math. Sci., associate professor at Irkutsk National Research Technical University, AuthorID: 128334, SPIN: 2774-4751, ORCID: 0000-0001-9562-7903. lempert@icc.ru, 664033, Russia, Irkutsk.*

**Tran Tuan Viet.** *PhD student at Irkutsk National Research Technical University, AuthorID: 1345480, SPIN: 7043-1530, ORCID: 0009-0008-1048-1473. mr.ttviet.1986@gmail.com, 664033, Russia, Irkutsk.*

*Статья поступила в редакцию 17.03.2026; одобрена после рецензирования 13.04.2026; принята к публикации 19.05.2026.*

*The article was submitted 03/17/2026; approved after reviewing 04/13/2026; accepted for publication 05/19/2026.*

## Метрический анализ сходства композиционных данных для нечеткого поиска релевантных рецептур эластомерных смесей

Рыбанов Александр Александрович, Каблов Виктор Федорович

Волжский политехнический институт (филиал) Волгоградского государственного технического университета, Россия, Волжский, [rybanoff@yandex.ru](mailto:rybanoff@yandex.ru)

**Аннотация.** В статье рассматривается актуальная задача разработки специализированных методов для поиска и ранжирования близких по составу рецептур резиновых смесей в базах данных. Целью исследования является разработка и сравнительный анализ метрик сходства, адаптированных для количественной оценки близости многокомпонентных композиционных данных, представленных в виде нормированных векторов весовых долей ингредиентов. Основное содержание работы включает формальную постановку задачи идентификации релевантных рецептур, требующую максимизации комплексной функции сходства, учитывающей как качественный состав (наличие ингредиентов), так и количественные пропорции. В качестве инструментария предложены и адаптированы четыре метрики: взвешенные коэффициенты Жаккара и Дайса, сходство Хеллингера и косинусное сходство. Теоретический анализ их свойств дополнен эмпирической валидацией на реальной промышленной базе данных, содержащей 6096 уникальных рецептур. Научная новизна исследования заключается в систематическом применении и адаптации аппарата метрического анализа к задаче поиска аналогов для композиционных данных материаловедения, а также в выявлении фундаментальной кластеризации рассматриваемых мер сходства. В отличие от существующих подходов, фокусирующихся на бинарном представлении состава или прогнозе свойств, представленная методология целенаправленно решает задачу точного поиска по составу и пропорциям. Полученные результаты выявили практически функциональную эквивалентность взвешенных коэффициентов Жаккара и Дайса (коэффициент корреляции  $r=0.991$ ), образующих один кластер мер, чувствительных к полному набору компонентов. Сходство Хеллингера и косинусное сходство продемонстрировали сильную корреляцию ( $r=0.883$ ), сформировав второй кластер мер, ориентированных на оценку структурного подобия пропорций, при этом метрика Хеллингера показала повышенную чувствительность к вариациям долей минорных ингредиентов. На основе этого сформулированы практические рекомендации по комбинированному использованию одной метрики из каждого кластера для создания эффективных поисковых систем. Разработанный метрический аппарат создает формальную основу для интеллектуального поиска аналогов, автоматизации подбора компонентов и сокращения времени на разработку новых рецептур в промышленности.

**Ключевые слова:** рецептуры резиновых смесей, поиск аналогов, метрики сходства, взвешенный коэффициент Жаккара, коэффициент Дайса, сходство Хеллингера, косинусное сходство, композиционные данные, база данных, материаловедение

**Цитирование:** Рыбанов А.А. Метрический анализ сходства композиционных данных для нечеткого поиска релевантных рецептур эластомерных смесей / А.А. Рыбанов, В.Ф. Каблов // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 102-116. – DOI:10.25729/ESI.2026.42.2.008.

**Введение.** Современное материаловедение характеризуется возрастающей сложностью проектирования многокомпонентных систем, к которым относятся рецептуры резиновых смесей. Задача идентификации близких по составу рецептур в базах данных формулируется как поиск и ранжирование образцов, максимально приближенных по качественному составу и количественным пропорциям ингредиентов к заданной целевой рецептуре [1]. Актуальность решения обусловлена высокой комбинаторной сложностью составов, где даже незначительные вариации весовых долей компонентов могут детерминировать технологические и эксплуатационные характеристики конечного продукта [2]. Специфика объекта исследования требует разработки специализированных методов сравнения, учитывающих композиционную природу данных (сумма долей равна 100%), высокую

размерность признакового пространства и необходимость работы с количественными характеристиками [3].

Проведенный анализ публикаций, посвященных управлению рецептурами резиновых смесей, свидетельствует о существенном прогрессе в области цифровизации материаловедения, однако выявляет значительный пробел в решении задачи поиска близких аналогов. Исследования в области моделирования технологических процессов [4] демонстрируют важность точного контроля состава для управления свойствами материалов, но не предлагают методов для поисковых операций в базах данных. Разработки в области автоматизации расчета рецептур [5] подтверждают общую тенденцию к цифровизации, однако не содержат алгоритмов оценки схожести между рецептами. Применение алгоритмов поиска ассоциативных правил для выявления статистически значимых сочетаний компонентов [6] имеет фундаментальное ограничение – подход оперирует бинарными данными и не учитывает весовые доли, что делает его неприменимым для решения задачи точного поиска аналогов по составу и пропорциям. Эволюция информационных систем в сторону интеллектуальных хранилищ с интеграцией искусственного интеллекта [7] и создание автоматизированного банка данных нового поколения [8] формируют технологическую основу для внедрения сложных алгоритмов поиска, однако конкретные методы и метрики для идентификации близких по составу рецептур в указанных работах не представлены.

Для решения поставленной задачи необходим аппарат, позволяющий количественно оценивать близость между рецептурами, представленными в виде векторов весовых долей в  $n$ -мерном пространстве ингредиентов. Анализ литературных данных показывает перспективность использования улучшенной метрики *sqrt-cosine similarity*, демонстрирующей повышенную точность на разреженных данных [9]. Эффективность комбинирования различных метрик для повышения точности в сложных доменах [10] может быть продуктивно применена к многокритериальной оценке сходства рецептур. Систематизация мер подобия в контексте рекомендательных систем [11] предоставляет теоретическую базу для ранжирования рецептур-кандидатов, а универсальная технология оценки близости информационных объектов [12] предлагает методологический каркас для работы с рецептурами. Исследования по метрической классификации с использованием метода  $k$ -ближайших соседей [13] подтверждают применимость данного алгоритма для задач поиска аналогов, однако подчеркивают критическую зависимость его эффективности от адекватности выбранной метрики расстояния.

Таким образом, проведенный анализ позволяет идентифицировать существенный пробел на стыке материаловедения и компьютерных наук. Существующие системы управления рецептурами не предлагают оптимизированных решений для точного поиска близких по составу и пропорциям рецептур, в то время как арсенал прикладной математики содержит разнообразные метрики и алгоритмы, чья эффективность для работы с композиционными, многокомпонентными и разреженными данными рецептур требует тщательной верификации и адаптации. Задачами настоящего исследования являются разработка и сравнительный анализ специализированных методов и метрик для оценки сходства рецептур резиновых смесей, направленных на эффективную идентификацию ближайших аналогов в информационных базах данных с учетом как качественного состава, так и количественных пропорций ингредиентов.

### **1. Постановка задачи идентификации релевантных рецептур резиновых смесей.**

Рассмотрим задачу поиска и ранжирования рецептур резиновых смесей в базе данных на основе количественного измерения их комплексного сходства с запросом (целевой

рецептурой), учитывающего как качественный состав (набор ингредиентов), так и количественные характеристики рецептуры (весовые доли компонентов).

Входными данными для задачи идентификации близких рецептов резиновых смесей являются:

1. Целевая рецептура (запрос), представленная как:

$$R_{target} = \{(c_i, w_{target.i}) | i = 1, 2, \dots, m\},$$

где  $i$  – индекс ингредиента, последовательно принимающий значения от 1 до  $m$  ( $m$  – количество ингредиентов в  $R_{target}$ );  $c_i$  – уникальный идентификатор где  $i$ -го ингредиента резиновой смеси  $R_{target}$ ;  $w_{target.i}$  – весовая доля ингредиента  $c_i$  в рецептуре  $R_{target}$ ,  $w_{target.i} > 0$ ,  $\sum_{i=1}^m w_{target.i} = 1$ .

2. База данных рецептов резиновых смесей:

$$DB = \{R_k | k = 1, 2, \dots, N\},$$

где  $N$  – количество рецептов в базе данных  $DB$ ;  $R_k$  – рецептура, представленная аналогично запросу (целевой рецептуре в  $R_{target}$ ), как  $R_k = \{(c_j, w_{k.j}) | j = 1, 2, \dots, m_k\}$ .

Для формализации поиска введём упорядоченное множество всех возможных ингредиентов:

$$C = \{c_j | j = 1, 2, \dots, n\},$$

где  $n$  – общее количество уникальных ингредиентов во всей системе ( $DB$  и  $R_{target}$ );  $C = \bigcup_{k=1}^N \text{comp}(R_k) \cup \text{comp}(R_{target})$ ,  $\text{comp}(R)$  – оператор извлечения идентификаторов рецептуры  $R$ ;

Каждая рецептура  $R_k \in DB \cup R_{target}$  преобразуется в векторы фиксированной размерности, соответствующей универсальному множеству всех уникальных ингредиентов, встречающихся в рецептурах резиновых смесей.

$$V(R_k) = \{v_j | j = 1, 2, \dots, n\} \in \mathbb{R}^n,$$

где координата  $v_j$  соответствует ингредиенту  $c_j \in C$ :

$$v_j(R_k) = \begin{cases} w_{k.j}, & \text{если } c_j \in R_k \text{ как } (c_j, w_{k.j}) \\ 0, & \text{если } c_j \notin R_k \end{cases}.$$

Координаты вектора соответствуют весовым долям конкретных компонентов; отсутствие компонента в рецептуре кодируется нулевым значением.

Ключевым элементом постановки задачи является определение комплексной функции сходства  $\text{Sim}(V(R_{target}), V(R_k))$ , количественно оценивающей близость вектора целевой рецептуры  $V(R_{target})$  к вектору рецептуры из базы данных  $V(R_k)$ . Эта функция должна удовлетворять двум фундаментальным требованиям: во-первых, учитывать факт наличия или отсутствия каждого ингредиента в сравниваемых рецептурах; во-вторых, интегрировать различия в весовых долях присутствующих ингредиентов. Функция  $\text{Sim}(V(R_{target}), V(R_k))$ , должна удовлетворять следующим условиям:

- $\text{Sim}(V(R_{target}), V(R_k)) \in [0, 1]$
- $\text{Sim}(V(R_{target}), V(R_{target})) = 1$  (максимальное сходство вектора целевой рецептуры с самим собой).
- чем больше значение  $\text{Sim}(V(R_{target}), V(R_k))$ , тем ближе рецептура  $R_k$  к  $R_{target}$ .

Постановку задачи идентификации релевантных рецептов резиновых смесей сформулируем следующим образом: разработать алгоритм идентификации и ранжирования рецептов резиновых смесей из базы данных  $DB$ , максимизирующих меру сходства с целевой рецептурой  $R_{target}$  в соответствии с заданной функцией сходства  $\text{Sim}$ .

Пусть заданы:

- База данных  $DB = \{R_k | k = 1, 2, \dots, N\}$  из  $N$  рецептов;
- Целевая рецептура  $R_{target}$ ;
- Функция сходства  $Sim(V(R_{target}), V(R_k))$ .

Требуется найти ранжированное подмножество  $S^* \subseteq DB$  мощностью  $K \leq N$ :

$$S^* = \{R_{S_1}, R_{S_2}, \dots, R_{S_K}\},$$

удовлетворяющее двум условиям:

- 1) условие оптимальности (доминирования по сходству):

$$\forall R_{S_i} \in S^*, \forall R_j \in DB \setminus S^*: Sim(V(R_{target}), V(R_{S_i})) > Sim(V(R_{target}), V(R_j));$$

- 2) последовательность  $\{R_{S_1}, R_{S_2}, \dots, R_{S_K}\}$  упорядочена по убыванию меры сходства (условие монотонного убывания):

$$Sim(V(R_{target}), V(R_{S_1})) \geq Sim(V(R_{target}), V(R_{S_2})) \geq \dots \geq Sim(V(R_{target}), V(R_{S_K})),$$

Предлагаемая формализация задачи представляет существенную практическую ценность для материаловедения, непосредственно способствуя решению ключевых прикладных задач при проектировании резиновых смесей: идентификации технологически эквивалентных составов; ранжированной визуализации альтернативных рецептов; автоматизации подбора компонентной базы; минимизации временных ресурсов, затрачиваемых на разработку новых композиций.

**2. Метрики сходства рецептов резиновых смесей.** В контексте задачи идентификации релевантных рецептов резиновых смесей предлагается к рассмотрению класс метрик сходства, основанных на операциях с непрерывными весовыми долями компонентов. Эти метрики предполагают интерпретацию рецептов, как векторов в многомерном пространстве ингредиентов. Они обеспечивают градуированную количественную оценку близости составов резиновых смесей, учитывающую как наличие совпадающих компонентов, так и вариации их весовых соотношений. Каждая метрика характеризуется уникальным набором формально выраженных свойств, детерминирующих ее чувствительность к специфическим типам расхождений: различиям в пропорциях общих ингредиентов, наличию компонентов, уникальных для одного из составов, либо отклонениям в концентрациях минорных составляющих.

В рамках настоящего исследования рассматриваются четыре ключевые метрики, адаптированные для анализа нормированных весовых долей ингредиентов:

**Взвешенный коэффициент Жаккара.** Для целевой рецептуры  $R_{target}$  и рецептуры  $R_k$  из базы данных, функция сходства на основе взвешенного коэффициента Жаккара определяется как:

$$Sim_J(V(R_{target}), V(R_k)) = \frac{\sum_{j=1}^n \min(v_j(R_{target}), v_j(R_k))}{\sum_{j=1}^n \max(v_j(R_{target}), v_j(R_k))} = \frac{\sum_{j=1}^n \min(w_{target,j}, w_{k,j})}{\sum_{j=1}^n \max(w_{target,j}, w_{k,j})},$$

где  $n$  – мощность универсального множества ингредиентов  $C$ ;  $w_{target,j}$  – весовая доля  $j$ -го ингредиента в  $R_{target}$  (0 при отсутствии);  $w_{k,j}$  – весовая доля  $j$ -го ингредиента в  $R_k$  (0 при отсутствии);

В отличие от бинарного аналога, оперирующего дискретными индикаторами наличия ингредиентов, взвешенный коэффициент Жаккара использует непрерывные весовые доли компонентов, что обеспечивает количественную оценку сходства рецептов. Ключевая семантика метрики определяется операциями над множествами: числитель  $\sum_{j=1}^n \min(w_{target,j}, w_{k,j})$  интерпретируется, как пересечение рецептов, отражающее

суммарный вклад ингредиентов, присутствующих в обоих составах, взвешенный по минимальным долям; знаменатель  $\sum_{j=1}^n \max(w_{target,j}, w_{k,j})$  характеризует их объединение, учитывающее все уникальные компоненты через максимальные доли. Метрика демонстрирует высокую чувствительность к различиям: расхождение в долях общих ингредиентов ( $\min(w_j, w'_j) \ll \max(w_j, w'_j)$ ) снижает сходство, а отсутствие компонента в одной из рецептов ( $\min(w_j, 0) = 0, \max(w_j, 0) = w_j > 0$ ) уменьшает итоговое значение. Коэффициент нормирован на интервал  $[0,1]$ , где единица достигается исключительно при полном совпадении весовых долей всех компонентов ( $\forall j: w_{target,j} = w_{k,j}$ ), а нулевое значение соответствует отсутствию общих ингредиентов.

**Взвешенный коэффициент Дайса (Weighted Dice Coefficient).** Для целевой рецептуры  $R_{target}$  и рецептуры  $R_k$  из базы данных функция сходства на основе взвешенного коэффициента Дайса определяется как:

$$\begin{aligned} Sim_{Dice} (V(R_{target}), V(R_k)) &= \frac{2 \cdot \sum_{j=1}^n \min(v_j(R_{target}), v_j(R_k))}{\sum_{j=1}^n v_j(R_{target}) + \sum_{j=1}^n v_j(R_k)} = \\ &= \frac{2 \cdot \sum_{j=1}^n \min(w_{target,j}, w_{k,j})}{\sum_{j=1}^n w_{target,j} + \sum_{j=1}^n w_{k,j}}. \end{aligned}$$

Данная метрика фокусируется на совпадении компонентного состава рецептов, где числитель  $2 \cdot \sum_{j=1}^n \min(w_{target,j}, w_{k,j})$  отражает удвоенную сумму перекрытия весовых долей общих ингредиентов, а знаменатель  $\sum_{j=1}^n w_{target,j} + \sum_{j=1}^n w_{k,j}$  (равный 2 для нормированных рецептов) представляет суммарную массу обоих составов. В отличие от коэффициента Жаккара, явно учитывающего уникальные компоненты через операцию максимума, метрика Дайса концентрируется на совпадающих элементах, игнорируя несовпадения. Уникальные ингредиенты ( $w_{target,j} > 0, w_{k,j} = 0$  или наоборот) уменьшают сходство, внося нулевой вклад в числитель, но полный вклад в знаменатель, однако их влияние менее выражено, чем у Жаккара, где знаменатель дополнительно увеличивается через  $\max(w_j, 0)$ . Коэффициент строго нормирован на интервал  $[0,1]$ , достигая единицы исключительно при полном совпадении всех весовых долей всех компонентов ( $\forall j: w_{target,j} = w_{k,j}$ ) и нуля – при отсутствии общих ингредиентов ( $\sum_{j=1}^n \min(w_j, w'_j) = 0$ ). Для любых рецептов выполняется  $Sim_{Dice} \geq Sim_j$  с равенством только при идентичности составов или отсутствии уникальных ингредиентов.

**Сходство Хеллингера (Hellinger Similarity).** Сходство Хеллингера измеряет близость между целевой рецептурой  $R_{target}$  и рецептурой  $R_k$  из базы данных, интерпретируя их, как дискретные вероятностные распределения:

$$\begin{aligned} Sim_H (V(R_{target}), V(R_k)) &= 1 - \sqrt{\frac{1}{2} \sum_{j=1}^n \left( \sqrt{v_j(R_{target})} - \sqrt{v_j(R_k)} \right)^2} = \\ &= 1 - \sqrt{\frac{1}{2} \sum_{j=1}^n \left( \sqrt{w_{target,j}} - \sqrt{w_{k,j}} \right)^2}. \end{aligned}$$

Значения метрики всегда лежат в диапазоне  $[0,1]$ . Ключевой особенностью является повышенная чувствительность к различиям в пропорциях минорных ингредиентов: операция взятия квадратного корня  $\sqrt{w_j}$  усиливает относительные отклонения малых долей (например,

разница между 0.01 и 0.02 существеннее, чем между 0.1 и 0.11). При этом метрика корректно обрабатывает нулевые компоненты, что позволяет сравнивать рецептуры с несовпадающим составом. Благодаря этим свойствам сходство Хеллингера эффективно для задач, требующих точного учёта пропорций всех ингредиентов, включая второстепенные.

**Косинусное сходство (Cosine Similarity).** Косинусное сходство измеряет близость между целевой рецептурой  $R_{target}$  и рецептурой  $R_k$  из базы данных, представляя их, как векторы весовых долей в  $n$ -мерном пространстве компонентов. В отличие от метрик, требующих нормировки на сумму (например, Хеллингера), косинусное сходство фокусируется на угловой близости векторов, вычисляемой по формуле:

$$\begin{aligned} Sim_{cos}(V(R_{target}), V(R_k)) &= \frac{\sum_{j=1}^n v_j(R_{target}) \cdot v_j(R_k)}{\sqrt{\sum_{j=1}^n (v_j(R_{target}))^2} \cdot \sqrt{\sum_{j=1}^n (v_j(R_k))^2}} = \\ &= \frac{\sum_{j=1}^n w_{target,j} \cdot w_{k,j}}{\sqrt{\sum_{j=1}^n (w_{target,j})^2} \cdot \sqrt{\sum_{j=1}^n (w_{k,j})^2}} \end{aligned}$$

В отличие от метрик, чувствительных к нормировке суммы долей (например, Хеллингера), косинусное сходство фокусируется на схожести относительных пропорций компонентов, инвариантно к абсолютным масштабам векторов (общей массе рецептуры). Метрика принимает значения в диапазоне  $[0,1]$  и оптимальна для поиска рецептур со схожей структурой компонентов, когда критичны именно относительные соотношения, а не абсолютные количества или полный набор компонентов. Чувствительность к уникальным компонентам (нулевым значениям в одном из векторов) зависит от размерности пространства.

Выбор оптимальной метрики сходства осуществляется на основании специфики решаемой аналитической задачи, заданных требований к чувствительности к различным аспектам различий составов, а также соображений вычислительной эффективности.

**3. Результаты исследований.** В ходе исследования использовалась база данных промышленных рецептур резиновых смесей, содержащая информацию о компонентном составе, ингредиентах и характеристиках резиновых смесей с учетом технических синонимов [8, 14]. Общий объем анализируемого корпуса данных составил 6096 уникальных рецептур (рис. 1). На основе указанного массива данных была реализована процедура нечеткого поискового запроса, направленная на идентификацию релевантных рецептур резиновых смесей.

Анализ иерархического распределения видов каучука в рецептурах резиновых смесей БД, представленный на рис. 2, показывает, что хлоропеновый каучук лидирует с 1162 рецептурами, за ним следует натуральный каучук с 935 рецептурами, что свидетельствует об их универсальности и широком применении в различных отраслях. В то же время, такие виды, как бутиловый и стирол-бутадиеновый каучук, имеют значительно меньше рецептур, что может указывать на узкую область применения.

Фрагмент логической схемы базы данных, содержащей данные о составе рецептов резиновых смесей, на основе которых была сформирована выборка исходных данных для процедуры нечеткого поиска, представлен на рис. 2.

Представленная схема отображает ключевые сущности («Рецептура», «Ингредиент») и связи между ними типа «входит в состав». Данная модель обеспечивает однозначную идентификацию компонентного состава каждой рецептуры и ассоциированных с ней физико-механических свойств, что формирует основу для последующего метрического

анализа. Особенностью базы данных является наличие справочников технических синонимов ингредиентов и свойств резиновых смесей, которые, упрощают поиск информации и позволяют применять методы машинного обучения для анализа данных




Рис. 1. Иерархическое распределение видов каучука в базе данных

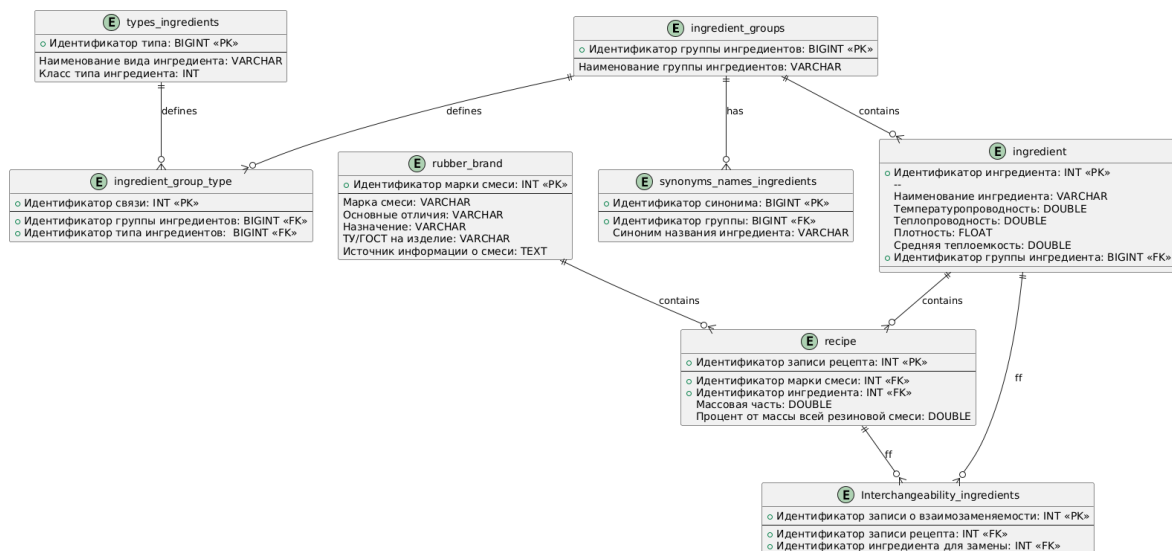


Рис. 2. Фрагмент логической схемы БД с исходными данными по составу рецептов резиновых смесей

На рис. 3 представлен компонентный состав резиновой смеси марки 1831-2, для которой с помощью процедуры нечёткого поиска были идентифицированы релевантные рецептуры-аналоги.

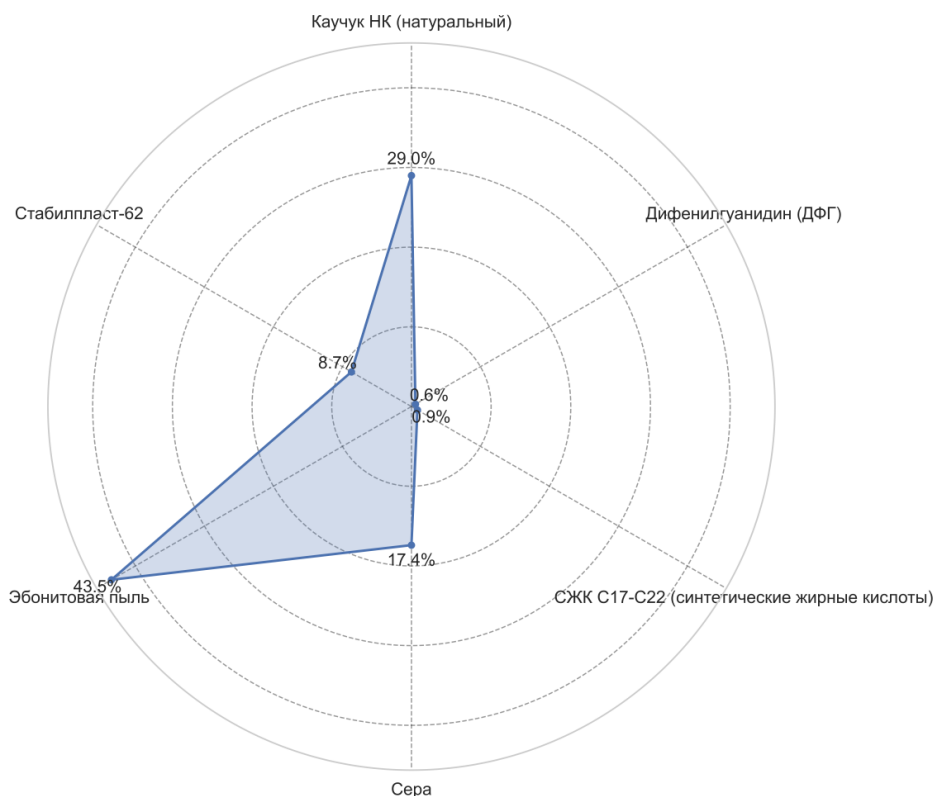


Рис. 3. Состав резиновой смеси марки 1831-2

Для каждой из четырёх метрик композиционного подобия (взвешенный коэффициент Жаккара, взвешенный коэффициент Дайса, сходство Хеллингера, косинусное сходство) выполнено ранжирование рецептов и селекция 10 максимально близких к эталону 1831-2. В результате объединения полученных множеств сформирована результирующая выборка из 15 уникальных промышленных марок (табл. 2), что математически подтверждает значимое пересечение отобранных рецептов для различных метрик (коэффициент перекрытия  $k=0.625$ ).


На основе результатов корреляционного анализа данных, представленных в таблице 2, выявлены следующие закономерности. Обнаружена практически функциональная эквивалентность метрик Жаккара ( $J$ ) и Дайса ( $D$ ), о чем свидетельствует их предельно сильная корреляция ( $r=0.991$ ,  $p<0.0001$ ), что предполагает их взаимозаменяемость при анализе сходства рецептов. Аналогично, установлена сильная корреляция между метрикой Хеллингера ( $H$ ) и косинусным сходством ( $C$ ) ( $r=0.883$ ,  $p<0.0001$ ), подтверждающая их общую природу, основанную на L2-нормировании и чувствительности к пропорциональному распределению компонентов. Все междуметрические корреляции между разными парами ( $J-H$ :  $r=0.932$ ;  $J-C$ :  $r=0.923$ ;  $D-H$ :  $r=0.899$ ;  $D-C$ :  $r=0.925$ ) оказались статистически высоко значимыми ( $p<10^{-5}$ ), демонстрируя фундаментальную согласованность всех исследуемых метрик в оценке композиционного сходства. Иерархия силы корреляционных связей ( $J-D > J-H \approx J-C > D-C > D-H > H-C$ ) указывает на максимальную близость  $J$  и  $D$  и относительно меньшую сопряженность  $H$  и  $C$ . Данные подтверждают гипотезу о двух кластерах:  $J-D$  (чувствительные к уникальным компонентам) и  $H-C$  (чувствительные к пропорциям). Практически это позволяет оптимизировать вычисления, используя по одной репрезентативной метрике из каждого кластера (например,  $J$  и  $C$ ), и интерпретировать

расхождения между кластерами как указание на различия в уникальности компонентов или пропорциях минорных ингредиентов. Высокая согласованность всех метрик подтверждает надежность оценки сходства рецептов и обосновывает их комбинированное применение для многомерного анализа.

**Таблица 2.** Результаты поиска рецептов резиновых смесей, композиционно близких к эталонной рецептуре марки 1831-2, на основе применения метрик сходства

№	ID рецептуры	Марка рецептуры	Взвешенный коэффициент Жаккара	Взвешенный коэффициент Дайса	Сходство Хеллингера	Косинусное сходство
1	799	1831-1	0.8400	0.9130	0.7051	0.9757
2	761	1791	0.8254	0.9043	0.7170	0.9821
3	3553	Л-1788	0.6102	0.7579	0.5942	0.9177
4	522	10998-1	0.5066	0.6725	0.4531	0.7366
5	521	10998	0.4435	0.6145	0.3916	0.7209
6	2130	6348-3	0.4356	0.6069	0.4381	0.7840
7	2129	6348-19	0.4356	0.6069	0.4381	0.7840
8	4184	Э-230	0.3767	0.5472	0.3499	0.6988
9	2072	6279-4	0.3678	0.5378	0.3518	0.5578
10	2071	6279-3	0.3678	0.5378	0.3518	0.5578
11	2174	640-13	0.3637	0.5334	0.4367	0.5567
12	2128	6345-8	0.3184	0.4831	0.3251	0.6055
13	2127	6345-7	0.3184	0.4831	0.3251	0.6055
14	963	24Р	0.3019	0.4638	0.4336	0.6014
15	4726	4508-3	0.1949	0.3262	0.3619	0.5312

С позиции прикладного материаловедения, полученные результаты (рис. 4) позволяют сформулировать конкретные методические рекомендации по выбору рецептов-аналогов.



**Рис. 4.** Матрица сходства рецептов по различным метрикам

Визуальный анализ матрицы позволяет выделить два ярко выраженных кластера рецептур: первый включает марки 1831-1, 1791 и Л-1788, демонстрирующие высокие значения сходства по всем метрикам, что указывает на их максимальную близость к эталону, как по компонентному составу, так и по пропорциям. Второй кластер образован рецептурами с умеренными и низкими показателями сходства (например, 10998-1, 6348-3, 6279-4), при этом внутри этого кластера наблюдается тесная группировка рецептур-пар (6348-3/6348-19, 6279-3/6279-4, 6345-7/6345-8), что свидетельствует о их внутренней схожести и, вероятно, общих технологических модификациях. Данная кластеризация наглядно демонстрирует практическую применимость метрик для категоризации рецептур по степени их взаимного сходства.


Важным аспектом методологии является интеграция экспертного знания в области рецептуростроения на всех стадиях работы – от формализации задачи до интерпретации выходных данных алгоритмов. В рамках проведенного исследования основной акцент сделан на объективной количественной валидации предлагаемых математических методов по их способности идентифицировать близкие аналоги в реальных промышленных данных. При этом детальная технологическая и производственная апробация каждого выявленного аналога, требующая натурального эксперимента, представляет собой отдельный, последующий этап внедрения, выходящий за рамки настоящей научной публикации, посвященной разработке и сравнению алгоритмических подходов.

**4. Обсуждение результатов.** Настоящее исследование было целенаправленно сфокусировано на фундаментальной задаче метрического сравнения композиционного состава рецептур, как на критически важном первом шаге информационного поиска в материаловедении. Разработанный и верифицированный метрический аппарат (раздел 2) создает формальную основу для решения этой задачи. Наша рабочая гипотеза, основанная на экспертизе в области проектирования эластомерных материалов, заключалась в том, что сходство состава является необходимым (хотя и не всегда достаточным) базисом для потенциального сходства свойств. Таким образом, разработанные методы идентификации близких по составу аналогов формируют естественную основу для последующей интеграции с прогнозными моделями «состав-свойство», что является логичным предметом следующих исследовательских задач.

Проведенный корреляционный анализ метрик сходства рецептур резиновых смесей выявил две принципиально различные группы мер близости с различными свойствами и областями применения. Исследование взаимосвязи между взвешенными коэффициентами Жаккара (J) и Дайса (D) (рис. 5) показало наличие статистически значимой линейной зависимости ( $r = 0,9911$ ;  $p < 0,0001$ ) с точным соответствием экспериментальных данных теоретической кривой, описываемой соотношением  $D = (2J)/(1 + J)$ . Данный результат свидетельствует о функциональной эквивалентности рассматриваемых метрик, что подтверждается наблюдаемым во всем диапазоне значений неравенством  $D \geq J$ , являющимся следствием математической природы данных мер.

В противоположность этому, корреляционный анализ между сходством Хеллингера (H) и косинусным сходством (C) (рис. 5) показал статистически значимую, но менее выраженную связь ( $r = 0,8826$ ;  $p < 0,0001$ ) с существенным разбросом экспериментальных точек. Данное обстоятельство указывает на комплементарный характер этих метрик, отражающих различные аспекты оценки сходства рецептур. Метрика Хеллингера демонстрирует повышенную чувствительность к вариациям концентраций минорных компонентов благодаря операции взятия квадратного корня, в то же время как косинусное

сходство более эффективно характеризует общую структурную схожесть пропорциональных соотношений ингредиентов.



**Рис. 5.** Корреляционная зависимость между взвешенными коэффициентами

Выбранные четыре метрики репрезентируют два фундаментальных и взаимодополняющих математических подхода к оценке близости композиционных данных: подход, основанный на операциях над множествами (взвешенные коэффициенты Жаккара и Дайса), и подход, основанный на измерении расстояний в векторном пространстве (сходство Хеллингера и косинусное сходство). Продемонстрированная функциональная эквивалентность внутри выявленных кластеров ( $J-D$  и  $H-C$ ) является ключевым результатом, подтверждающим адекватность и достаточность данного компактного набора мер для решения задачи многокритериальной классификации и ранжирования рецептов по степени сходства. Таким образом, использованная в исследовании база данных промышленных рецептов, репрезентующая значительный сегмент известных композиций, выступила адекватным полигоном для валидации предложенной методологии. Ключевым итогом является не получение результатов, специфичных для данной выборки, а выявление универсального принципа: целесообразность комбинирования метрик, репрезентирующих два выявленных кластера (основанных на операциях над множествами и на измерении расстояний). Данный принцип инвариантен к предметной области и применим для анализа других баз композиционных данных.

С практической точки зрения, установленная взаимозаменяемость метрик Жаккара и Дайса позволяет оптимизировать вычислительные алгоритмы путем использования только одной из них без ущерба для точности анализа. В то же время, комбинированное применение метрик Хеллингера и косинусного сходства обеспечивает многомерную оценку сходства рецептов, где расхождения в их показаниях содержат дополнительную информацию о характере различий между составами.

Таким образом, рациональная организация процедуры поиска аналогов в базах данных резиновых смесей может быть достигнута путем совместного использования одной метрики из кластера функционально эквивалентных мер ( $J$  или  $D$ ) и одной метрики из кластера комплементарных мер ( $H$  или  $C$ ). Данный подход обеспечивает оптимальный баланс между вычислительной эффективностью и полнотой анализа как качественного состава, так и количественных пропорций ингредиентов.

Предложенные и верифицированные метрики сходства служат базовыми компонентами для построения сложных поисковых и рекомендательных систем в

материаловедении. Детальное рассмотрение архитектур на основе искусственного интеллекта, таких, как системы, использующие нейросетевые эмбединги или глубокое обучение для прогнозирования свойств на основе состава, представляет собой отдельную масштабную исследовательскую задачу. Развитие таких систем в будущем будет опираться на полученный в данной работе фундамент – формализованный и проверенный на реальных данных метрический аппарат для оценки композиционного сходства.

**Заключение.** Проведенное исследование демонстрирует эффективность формализованного подхода к задаче идентификации близких по составу рецептур резиновых смесей. Разработанная постановка задачи поиска и ранжирования, основанная на максимизации комплексной функции сходства, представляет существенную практическую ценность для автоматизации проектирования новых композиций и поиска технологически эквивалентных замен.

Сравнительный анализ четырех метрик сходства позволил выявить их фундаментальные свойства и области рационального применения. Установлена функциональная эквивалентность взвешенных коэффициентов Жаккара и Дайса, что подтверждается предельно сильной корреляцией ( $r=0,991$ ) и их взаимозаменяемостью для оценки полного компонентного состава. С другой стороны, сходство Хеллингера и косинусное сходство, демонстрируя сильную, но менее выраженную связь ( $r=0,883$ ), образуют кластер комплементарных мер, ориентированных на анализ пропорциональных соотношений ингредиентов, где сходство Хеллингера проявляет повышенную чувствительность к минорным компонентам.

Полученные результаты позволяют сформулировать конкретные методические рекомендации. Для решения прикладных задач в материаловедении наиболее эффективной является стратегия комбинированного использования одной метрики из кластера «Жаккар-Дайс» (для контроля за полным набором ингредиентов) и одной из кластера «Хеллингера-Косинус» (для анализа структурного подобия пропорций). Такой подход обеспечивает оптимальный баланс между вычислительной эффективностью и полнотой анализа, позволяя интерпретировать расхождения между показаниями метрик из разных кластеров как указание на специфический характер различий между рецептурами.

Таким образом, работа вносит вклад как в развитие методов компьютерного анализа данных в материаловедении, так и в решение практических задач промышленного проектирования резиновых смесей, предлагая надежный и интерпретируемый инструмент для интеллектуального поиска в специализированных базах данных.

#### **Список источников**

1. Каблов В.Ф. Эволюция информационных систем управления рецептурами резиновых смесей: от баз данных к интеллектуальным хранилищам с интеграцией модулей искусственного интеллекта / В.Ф. Каблов, А.А. Рыбанов, М.А. Маслова // Каучук и резина-2025: Традиции и новации: материалы XIII Всероссийской конференции. – Москва, 2025. – С. 23-24.
2. Нигматуллин В.Р. Использование методов машинного обучения и искусственного интеллекта в химической технологии. Часть I / В.Р. Нигматуллин, Н.А. Руднев // Нефтегазовое дело, 2019. – № 4. – С. 243-268. – DOI: 10.17122/ogbus-2019-4-243-268
3. Rajan K., et al. Data mining and multivariate analysis in materials science. Molten salts: from fundamentals to applications, Dordrecht, Springer, 2002, p. 89-102.
4. Тихомиров С.Г. Управление процессом вулканизации на основе моделирования и оценки ключевых параметров модели / С.Г. Тихомиров, А.А. Маслов, О.В. Карманова и др. // Вестник ВГУ. Серия: Системный анализ и информационные технологии. – 2024. – № 4. – С. 22-34.
5. Матвеев Н.А. Автоматизация расчёта рецептуры резиновой смеси при помощи программного обеспечения / Н.А. Матвеев, А.П. Моргунов // Омский научный вестник, 2016. – № 5 (149). – С. 55-58.

6. Рыбанов А.А. Применение алгоритмов поиска ассоциативных правил для определения технологически значимых сочетаний компонентов в рецептурах резиновых смесей / А.А. Рыбанов, В.Ф. Каблов // Информационные и математические технологии в науке и управлении, 2025. – № 3 (39). – С. 177-188.
7. Рыбанов А.А. Интеграция синонимических систем в информационные системы управления рецептами резинотехнических материалов / А.А. Рыбанов, В.Ф. Каблов, М.А. Маслова // Вестник Череповецкого государственного университета, 2025. – № 5 (128). – С. 70-82.
8. Каблов В.Ф. Автоматизированный банк данных нового поколения рецептов и свойств резин / В.Ф. Каблов, А.А. Рыбанов, Н.А. Кейбал // Каучук и резина, 2024. – Т. 83. – № 3. – С. 168-173.
9. Sohngir S., Wang D. Improved sqrt-cosine similarity measurement. Journal of Big Data, 2017, vol. 4, no. 25, pp. 1-13, DOI:10.1186/s40537-017-0083-6.
10. Chen F., Farahat A., Brants T. Multiple similarity measures and source-pair information in story link detection. Proceedings of the Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics (HLT-NAACL 2004). Boston, MA, USA, 2004, pp. 313-320.
11. Порошкина В.В. Меры подобия в рекомендательных системах / В.В. Порошкина // Аллея науки, 2019. – Т. 1, № 4 (31). – С. 909-913.
12. Кузнецов Л.А. Универсальная технология оценки близости информационных объектов / Л.А. Кузнецов // Информатика и её применения, 2014. – Т. 8. – № 2. – С. 130-144.
13. Гороховатская Н.В. Метрическая классификация с использованием метода ближайших соседей на основе описаний в виде множеств признаков: дис. ... канд. техн. наук. – М., 2012. – 145 с.
14. База данных рецептов, ингредиентов и свойств резиновых смесей с учетом технических синонимов: свидетельство о гос. регистрации базы данных № 2025621312 Российская Федерация: № 2025620796: заявл. 12.03.2025: опубл. 24.03.2025 / В.Ф. Каблов, А.А. Рыбанов, Н.А. Кейбал и др.; правообладатель ВПИ (филиал) ВолГТУ.

*Рыбанов Александр Александрович. Кандидат технических наук, доцент, кафедра «Информатика и технология программирования», Волжский политехнический институт (филиал) Волгоградский государственный технический университет, заведующий кафедрой. AuthorID: 234968, SPIN: 9256-6050, ORCID: 0000-0002-8638-9998, rybanoff@yandex.ru. 404111, Волгоградская область, г. Волжский, пр-кт Ленина, 72.*

*Каблов Виктор Федорович. Доктор технических наук, профессор, кафедра «Химическая технология полимеров и промышленная экология», Волжский политехнический институт (филиал) Волгоградский государственный технический университет, профессор. AuthorID: 115782, SPIN: 1093-9003, ORCID: 0000-0002-2970-6109, vkablov5@gmail.com. 404111, Волгоградская область, г. Волжский, пр-кт Ленина, 72.*

UDC 004.8+004.942

DOI:10.25729/ESI.2026.42.2.008

## **Metric similarity analysis of compositional data for fuzzy search of relevant elastomeric mixture formulations**

**Alexander A. Rybanov, Victor F. Kablov**

Volzhsy Polytechnic Institute (Branch) of Volgograd State Technical University,  
Russia, Volzhsky, rybanoff@yandex.ru

**Abstract.** The article addresses the pressing task of developing specialized methods for searching and ranking rubber compound formulations with similar compositions in databases. The aim of the research is to develop and conduct a comparative analysis of similarity metrics adapted for quantitatively assessing the proximity of multi-component compositional data represented as normalized vectors of ingredient weight fractions. The core of the work includes a formal statement of the problem of identifying relevant formulations, which requires maximizing a comprehensive similarity function that considers both qualitative composition (presence of ingredients) and quantitative proportions. Four metrics are proposed and adapted as tools: weighted Jaccard and Dice coefficients, Hellinger similarity, and cosine similarity. A theoretical analysis of their properties is

supplemented by empirical validation on a real industrial database containing 6,096 unique formulations. The scientific novelty of the study lies in the systematic application and adaptation of metric analysis apparatus to the task of searching for analogues for compositional materials science data, as well as in revealing a fundamental clustering of the considered similarity measures. Unlike existing approaches focused on binary representation of composition or property prediction, the presented methodology purposefully solves the problem of precise search by composition and proportions. The obtained results revealed a near-functional equivalence of the weighted Jaccard and Dice coefficients (correlation coefficient  $r=0.991$ ), forming one cluster of measures sensitive to the full set of components. Hellinger similarity and cosine similarity demonstrated a strong correlation ( $r=0.883$ ), forming a second cluster of measures focused on assessing structural similarity of proportions, with the Hellinger metric showing increased sensitivity to variations in the fractions of minor ingredients. Based on this, practical recommendations are formulated for the combined use of one metric from each cluster to create effective search systems. The developed metric framework establishes a formal basis for intelligent analogue search, automation of component selection, and reduction of development time for new formulations in the industry.

**Keywords:** rubber compound formulations, search for analogues, similarity metrics, weighted Jaccard coefficient, Dice coefficient, Hellinger similarity, cosine similarity, compositional data, database, materials science

### References

1. Kablov V.F., Rybanov A.A., Maslova M.A. Evolyutsiya informatsionnykh sistem upravleniya retsepturami rezinovykh smesey: ot baz dannykh k intellektual'nym khranilishcham s integratsiyey moduley iskusstvennogo intellekta [Evolution of rubber compound recipe management information systems: from databases to intelligent repositories with integration of artificial intelligence modules]. *Kauchuk i rezina-2025: Traditsii i novatsii: materialy XIII Vserossiyskoy konferentsii* [Rubber and rubber-2025: Traditions and innovations: proceedings of the xiii All-russian conference]. Moscow, 2025, pp. 23-24.
2. Nigmatullin V.R., Rudnev N.A. Ispol'zovaniye metodov mashinnogo obucheniya i iskusstvennogo intellekta v khimicheskoy tekhnologii. Chast' I [Application of machine learning and artificial intelligence methods in chemical technology. Part I]. *Neftegazovoye delo* [Oil and gas business], 2019, no. 4, pp. 243-268, DOI: 10.17122/ogbus-2019-4-243-268.
3. Rajan K. Data mining and multivariate analysis in materials science. In: M. Gaune-Escard (ed.). *Molten Salts: From Fundamentals to Applications*. Dordrecht, Springer, 2002, pp. 89-102.
4. Tikhomirov S.G., Maslov A.A., Karmanova O.V. et al. Upravleniye protsessom vulkanizatsii na osnove modelirovaniya i otsenki klyuchevykh parametrov modeli [Control of the vulcanization process based on modeling and evaluation of key model parameters]. *Vestnik VGU. Seriya: Sistemnyy analiz i informatsionnyye tekhnologii* [Bulletin of VSU. Series: System analysis and information technologies], 2024, no. 4, pp. 22-34.
5. Matveev N.A., Morgunov A.P. Avtomatizatsiya rascheta retseptury rezinovoy smesi pri pomoshchi programmnoy obespecheniya [Automation of rubber compound recipe calculation using software]. *Omskiy nauchnyy vestnik* [Omsk scientific bulletin], 2016, no. 5 (149), pp. 55-58.
6. Rybanov A.A., Kablov V.F. Primeneniye algoritmov poiska assotsiativnykh pravil dlya opredeleniya tekhnologicheskikh znachimykh sochetaniy komponentov v retsepturakh rezinovykh smesey [Application of association rule mining algorithms for identifying technologically significant combinations of components in rubber compound recipes]. *Informatsionnyye i matematicheskiye tekhnologii v nauke i upravlenii* [Information and mathematical technologies in science and management], 2025, no. 3 (39), pp. 177-188.
7. Rybanov A.A., Kablov V.F., Maslova M.A. Integratsiya sinonimicheskikh sistem v informatsionnyye sistemy upravleniya retsepturami rezinotekhnicheskikh materialov [Integration of synonymic systems into information systems for managing rubber compound recipes]. *Vestnik Cherepovetskogo gosudarstvennogo universiteta* [Bulletin of Cherepovets state university], 2025, no. 5 (128), pp. 70-82.
8. Kablov V.F., Rybanov A.A., Keybal N.A. Avtomatizirovannyi bank dannykh novogo pokoleniya retseptur i svoystv rezin [Automated new-generation data bank of rubber formulations and properties]. *Kauchuk i rezina* [Rubber and rubber], 2024, vol. 83, no. 3, pp. 168-173.
9. Sohangir S., Wang D. Improved sqrt-cosine similarity measurement. *Journal of Big Data*, 2017, vol. 4, no. 25, pp. 1-13, DOI:10.1186/s40537-017-0083-6.
10. Chen F., Farahat A., Brants T. Multiple similarity measures and source-pair information in story link detection. *Proceedings of the Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics (HLT-NAACL 2004)*. Boston, MA, USA, 2004, pp. 313-320.
11. Poroshkina V.V. Mery podobiya v rekomendatel'nykh sistemakh [Similarity measures in recommender systems]. *Alleya nauki* [Alley of science], 2019, vol. 1, no. 4 (31), pp. 909-913.

12. Kuznetsov L.A. Universal'naya tekhnologiya otsenki blizosti informatsionnykh ob"yektov [Universal technology for estimating the proximity of information objects]. *Informatika i yeye primeneniya* [Informatics and its applications], 2014, vol. 8, no. 2, pp. 130-144.
13. Gorokhovatskaya N.V. *Metricheskaya klassifikatsiya s ispol'zovaniyem metoda blizhayshikh sosedey na osnove opisaniy v vide mnozhestv priznakov* [Metric classification using the nearest neighbor method based on descriptions in the form of feature sets]. PhD dissertation. Moscow, 2012, 145 p.
14. Kablov V.F., Rybanov A.A., Keybal N.A. et al. *Baza dannykh retseptur, ingredientov i svoystv rezinnykh smesey s uchetom tekhnicheskikh sinonimov* [Database of recipes, ingredients and properties of rubber compounds taking into account technical synonyms]. State registration certificate of database No. 2025621312 Russian Federation: No. 2025620796: appl. 03.12.2025: publ. 03.24.2025; rightholder VPI (branch) VolgSTU.

**Alexander Aleksandrovich Rybanov.** *PhD in Engineering, Associate Professor, Head of the Department of "Informatics and Programming Technology", Volzhsky Polytechnic Institute (branch) of Volgograd State Technical University. AuthorID: 234968, SPIN: 9256-6050, ORCID: 0000-0002-8638-9998, rybanoff@yandex.ru. 404111, Volgograd Region, Volzhsky, Lenin Ave, 72.*

**Victor Fedorovich Kablov.** *Doctor in Engineering, Professor, Department of "Chemical Technology of Polymers and Industrial Ecology", Volzhsky Polytechnic Institute (branch) of Volgograd State Technical University. AuthorID: 115782, SPIN: 1093-9003, ORCID: 0000-0002-2970-6109, vkablov5@gmail.com. 404111, Volgograd Region, Volzhsky, Lenin Ave, 72.*

*Статья поступила в редакцию 18.12.2025; одобрена после рецензирования 10.02.2026; принята к публикации 15.05.2026.*

*The article was submitted 12/18/2025; approved after reviewing 02/10/2026; accepted for publication 05/15/2026.*

## Математические, информационные и интеллектуальные технологии в энергетике

УДК 621.311.25-047.36:004.032.26:004.932

DOI:10.25729/ESI.2026.42.2.009

### Обучение сверточной нейросетевой модели методом Active learning для мониторинга безопасности объектов теплоэнергетики

Кулагина Людмила Владимировна, Шефер Эдуард Артурович

Сибирский федеральный университет, Россия, Красноярск, [shefer.eduardov-119sp@list.ru](mailto:shefer.eduardov-119sp@list.ru)

**Аннотация.** Обеспечение промышленной безопасности объектов теплоэнергетики сопряжено с необходимостью применения эффективных и надежных средств раннего обнаружения потенциально пожароопасных и аварийных ситуаций. Эта задача осложняется специфическими условиями эксплуатации, характеризующимися широким диапазоном рабочих режимов, высоким уровнем электромагнитных помех и вибраций, а также, зачастую, ограниченным объемом размеченных данных, пригодных для обучения и верификации систем мониторинга и прогнозирования. Целью данной работы является разработка и экспериментальная валидация комплексного подхода к повышению точности и надежности систем компьютерного зрения для мониторинга безопасности теплоэнергетических объектов на основе методологии активного обучения. В качестве основных методов используются сверточные нейросетевые модели детекции объектов архитектуры YOLOv8, эвристический механизм отбора информативных данных по метрике неопределенности, а также инструменты объяснимого искусственного интеллекта и отказоустойчивого принятия решений с участием эксперта. Научная новизна работы заключается в адаптации методов Active Learning к однопроходным детекторам для задач промышленной безопасности, а также в интеграции цикла целевой доразметки сложных примеров с механизмами интерпретации и гибридной верификации результатов (что позволяет минимизировать затраты на разметку (за счёт выборочного запроса «сложных» примеров); оперативно адаптироваться к новым типам аномалий (например, нестандартным утечкам, локальным перегревам)); тогда как в большинстве публикаций по безопасности теплоэнергетических объектов используются классические методы машинного обучения (SVM, случайные леса) либо предобученные CNN без адаптации под специфику отрасли. В выполненной работе экспериментальные исследования на специализированном датасете изображений объектов теплоэнергетики показали, что применение активного обучения обеспечивает прирост показателя mAP@0.5:0.95 на 28,32 % и увеличение полноты обнаружения на 7,82 % по сравнению со стандартным обучением. Полученные результаты подтверждают перспективность предложенного подхода для практического применения в системах мониторинга и раннего оповещения, способных обеспечить своевременное выявление отклонений от нормальных параметров функционирования оборудования и предотвращение развития аварийных сценариев.

**Ключевые слова:** активное обучение, сверточные нейросети, YOLOv8, промышленная безопасность, объекты теплоэнергетики

**Цитирование:** Кулагина Л.В. Обучение сверточной нейросетевой модели методом Active learning для мониторинга безопасности объектов теплоэнергетики / Л.В. Кулагина, Э.А. Шефер // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 117-127. – DOI:10.25729/ESI.2026.42.2.009.

**Введение.** Объекты теплоэнергетики, включая котельные установки, теплоэлектроцентрали, системы теплогенерации и теплообменное оборудование, относятся к категории потенциально опасных производственных объектов. Их эксплуатация осуществляется в условиях высоких температур, давления и непрерывных технологических процессов, что предъявляет повышенные требования к системам мониторинга и раннего обнаружения нештатных ситуаций. Современные тенденции модернизации теплоэнергетических объектов, направленные на повышение энергетической эффективности и автоматизацию управления, приводят к усложнению режимов эксплуатации и росту требований к надежности средств промышленной безопасности. Одним из перспективных направлений повышения уровня безопасности является применение методов искусственного

интеллекта и компьютерного зрения для автоматического обнаружения пожароопасных ситуаций, таких, как возгорание, задымление и аномальные тепловые режимы. Сверточные нейросетевые модели продемонстрировали высокую эффективность в задачах распознавания визуальных образов, однако их практическое внедрение в промышленную сферу сталкивается с рядом ограничений.

Ключевой проблемой является дефицит специализированных размеченных данных, отражающих реальную специфику теплоэнергетических объектов, включая особенности визуального проявления дыма и пламени на фоне технологического оборудования, влияние инфракрасного и видимого спектров, а также редкость аварийных событий и выраженный дисбаланс классов, в отличие от задач общего компьютерного зрения, для которых доступны крупные открытые датасеты. В области промышленной безопасности теплоэнергетики универсальные наборы данных оказываются недостаточно репрезентативными, что обуславливает необходимость разработки методов, позволяющих эффективно использовать ограниченные объемы данных и целенаправленно повышать качество моделей за счет привлечения экспертных знаний. В этом контексте особый интерес представляет методология активного обучения (Active Learning), предполагающая итеративный отбор наиболее информативных примеров для последующей разметки и дообучения модели.

Значительный массив исследований по применению методов искусственного интеллекта для распознавания аварийных ситуаций накоплен в смежных областях промышленной безопасности. В частности, активно развиваются методы компьютерного зрения для раннего обнаружения лесных пожаров, основанных на анализе динамики дыма и пламени, а также системы мониторинга аварий на объектах химической и горнодобывающей промышленности, где используются модели для выявления утечек, взрывов и разрушений оборудования.

Существенный опыт также накоплен в задачах визуального и сенсорного контроля транспортных систем и объектов хранения горючих сред, вместе с тем прямой перенос указанных решений на объекты теплоэнергетики оказывается затруднительным вследствие отличий в характере визуального фона, преобладания технологического пара, высокотемпературного пара, высокотемпературных поверхностей и специфике режимов эксплуатации [1-5].

Целью данной работы является разработка комплексного подхода к обучению сверточной нейросетевой модели детекции пожароопасных ситуаций на объектах теплоэнергетики с использованием активного обучения, а также экспериментальная оценка эффективности предложенного решения по сравнению со стандартным обучением [6-8].

**1. Специфика визуального мониторинга объектов теплоэнергетики и подготовка данных.** Визуальный мониторинг объектов теплоэнергетики обладает рядом специфических особенностей, существенно отличающих его от задач общего назначения. Во-первых, целевые признаки аварийных ситуаций, такие, как дым и пламя, часто имеют размытые границы и неустойчивую форму, а их визуальное проявление зависит от условий освещения, ракурса съемки и спектрального диапазона. Во-вторых, на изображениях присутствуют интенсивные фоновые помехи, связанные с нагретыми поверхностями, парообразованием, отражениями и вибрациями оборудования. В-третьих, аварийные события являются редкими, что приводит к сильному дисбалансу между классами «норма» и «опасная ситуация».

Указанные факторы существенно осложняют применение стандартных подходов к обучению нейросетевых моделей и делают недостаточным использование универсальных датасетов, сформированных для общих задач детекции огня или дыма. В рамках данной работы исходные данные формировались на основе изображений объектов теплоэнергетики,

включая котельные и теплогенерирующие установки, в видимом спектре и с учетом характерных условий эксплуатации.

Подготовка входных данных включает в себя поиск качественных материалов, а также их предобработку, которая включает в себя разметку боксов и присвоение классов объектам. Зачастую практика такова, что большинство обучений происходит на заранее сформированном наборе данных [9-11] взятом из интернет-ресурсов, таких, как: «Roboflow», «Github», «HugginFace». Здесь преимуществом является быстрый доступ к обучению модели без долгой консолидации входных данных, однако универсальный характер этих платформ становится недостатком при решении узкоспециализированных прикладных задач (например, таких, как мониторинг безопасности объектов теплоэнергетики), для которых характерны специфические условия видеофиксации, уникальные ракурсы технологического оборудования, особая визуальная природа целевых объектов (дым, пламя в инфракрасном и видимом спектрах), а также выраженный дисбаланс классов. В результате готовых, качественно размеченных наборов данных, которые могут использоваться для подобной специализации, практически не существует.

Отмеченное противоречие между потребностью в больших объемах размеченных данных и их фактическим отсутствием для специфичных индустриальных сценариев формирует основную проблему на старте разработки. Решение лежит не в поиске готовых решений, а в создании собственного цикла формирования и улучшения датасета. Такой цикл должен начинаться с первичного сбора сырых данных и их ручной экспертной разметки с помощью специализированных инструментов. Для подготовки обучающей выборки был разработан специализированный десктопный инструмент ручной разметки изображений с графическим интерфейсом. Приложение обеспечивает создание и редактирование ограничивающих рамок, присвоение классов и экспорт аннотаций в формате YOLOv8. Использование собственного инструмента разметки позволило сформировать первичный датасет, отражающий реальную визуальную специфику теплоэнергетических объектов, однако его объем оказался недостаточным для достижения высокой надежности модели при стандартном обучении, что обусловило необходимость применения активного обучения.

**2. Метод обучения «Active learning».** Активное обучение представляет собой итеративный подход к машинному обучению, в котором модель самостоятельно определяет наиболее информативные данные для последующей разметки экспертом. В отличие от пассивного обучения на фиксированном наборе данных, Active Learning позволяет целенаправленно концентрировать усилия на примерах, вызывающих наибольшую неопределенность в предсказаниях модели.

Классические стратегии активного обучения разрабатывались преимущественно для задач классификации и требуют адаптации при применении к задачам детекции объектов, где модель одновременно предсказывает координаты ограничивающих рамок и вероятности классов. В нашей работе предложен эвристический механизм оценки неопределенности для однопроходного детектора YOLOv8, основанный на анализе распределения уверенности детекций и отборе предсказаний с промежуточными значениями confidence. Такие примеры, находящиеся вблизи решающей границы, обладают наибольшей информационной ценностью для последующего дообучения модели.

Итеративный цикл активного обучения включает следующие этапы: начальное обучение модели на первичном размеченном датасете; инференс на пуле неразмеченных данных с пониженным порогом уверенности; вычисление метрики неопределенности и отбор сложных примеров; экспертную разметку отобранных изображений; дообучение модели и повторную

валидацию. Данный цикл повторяется до достижения требуемых показателей качества [11-14].

В контексте подготовки данных для нейросетевых моделей в компьютерном зрении, активное обучение успешно применяется для задач семантической сегментации [11, 12], классификации медицинских изображений и детекции объектов в беспилотных системах. Например, в работе по обнаружению дефектов на производственных линиях этот метод позволил сократить объем ручной разметки на 40%, сохранив прирост точности. Подход в принципе остается единым: после начального обучения на небольшом размеченном датасете модель оценивает неразмеченные данные, выявляет среди них наиболее «проблемные» случаи, которые затем отправляются эксперту для разметки и добавляются в обучающую выборку. Цикл повторяется до достижения требуемых метрик качества, однако прямое применение классических подходов активного обучения к современным однопроходным детекторам, таким, как YOLOv8 [15], используемым в предлагаемой работе, сопряжено с техническими и методологическими сложностями. Пример «проблемного» случая детекции объекта представлен на рисунке 1.



**Рис. 1.** Пример «проблемного» случая детекции объекта

Стандартные стратегии, разработанные для моделей классификации, требуют адаптации к архитектуре, которая одновременно предсказывает координаты bounding boxes и вероятности классов, более того, для промышленных систем безопасности критически важны не только точность, но и интерпретируемость решений модели, а также отказоустойчивость в условиях неопределенности, следовательно, необходима комплексная реализация активного обучения, которая интегрирует механизм интеллектуального отбора данных и инструменты для анализа ошибок модели и системы безопасности для принятия решений в гибридном режиме «автоматика-эксперт».

Выполненное исследование направлено на преодоление указанных ограничений путем разработки и внедрения специализированного инструментария, реализующего полный цикл активного обучения для задачи детекции пожароопасных ситуаций для теплоэнергетических объектов.

**3. Разработанные инструменты для использования «Active learning».** Разработанная система программных инструментов образует комплексное решение полного цикла работ с системами компьютерного зрения, первым компонентом которой является интерактивный инструмент ручной разметки, реализованный как десктопное приложение с графическим интерфейсом на базе Tkinter, что обеспечивает кроссплатформенность и простоту развертывания без дополнительных зависимостей.

Архитектурно программа следует принципам объектно-ориентированного проектирования, где класс `AnnotationData` инкапсулирует логику хранения и преобразования аннотаций, а `InteractiveLabelingTool` объединяет управление состоянием и визуальное представление. Ключевой особенностью инструмента являются двунаправленные конвертации между абсолютными координатами ограничивающих рамок и нормализованным форматом YOLOv8, что обеспечивает совместимость с современными конвейерами обучения нейронных сетей. Вид графического интерфейса представлен на рисунке 2.

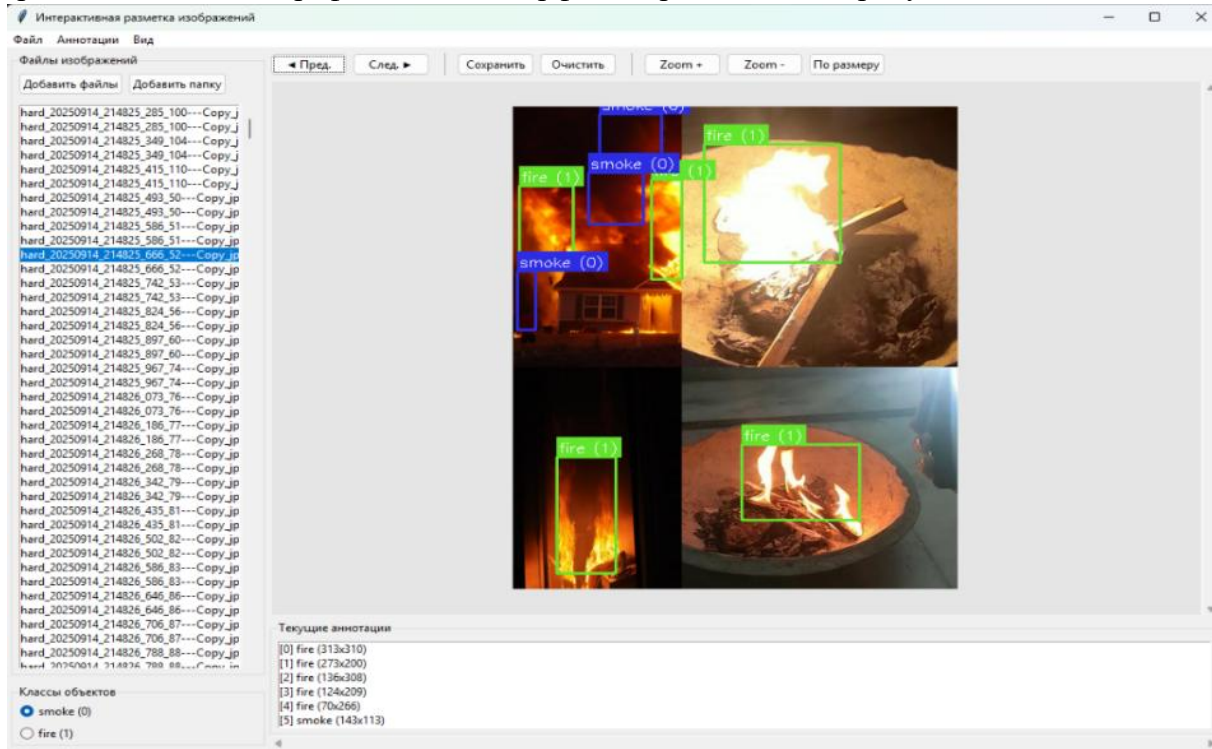


Рис. 2. Вид графического интерфейса

Графическая оболочка спроектирована с учетом эргономики длительной работы оператора, реализуя интуитивную модель взаимодействия через сочетания мыши и «горячих» клавиш, двухпанельная компоновка разделяет область навигации по файлам и выбор классов объектов от основной рабочей зоны просмотра и разметки изображений, механизм bounding boxes использует событийно-ориентированную парадигму с визуальной обратной связью. На всех этапах работы система адаптирует масштабирование с алгоритмом подгонки изображений под размер окна просмотра, интеллектуальное управление состоянием аннотаций с предотвращением потери данных при переходе между изображениями и экспорт результатов в структурированном виде с метаданными проекта.

Второй компонент системы – набор посттренировочных инструментов для YOLOv8, представляет собой концептуально более сложный модуль, реализующий три современных подхода к улучшению промышленных систем компьютерного зрения.

Движок активного обучения построен на принципе неопределенности семплирования, где вместо случайного выбора данных для дополнительной разметки система идентифицирует примеры, в которой модель демонстрирует промежуточную уверенность; сомнительные предсказания, находящиеся вблизи решающей границы классификатора, обладают максимальной информационной ценностью для дообучения модели. Алгоритм выполняет сканирование датасета с автоматическим определением структуры каталогов, инференс с пониженным порогом уверенности для захвата всех гипотез модели, количественную оценку неопределенности через специальную метрику и фильтрацию артефактов по минимальной

площади bounding box. Результатом работы является набор сложных примеров, готовых к целевой доразметке, с полным аннотированием и структурированными метаданными.

Модуль объяснимого искусственного интеллекта [16, 17] решает задачу интерпретации решений модели детекции, что критически важно для повышения доверия к системе и ее отладки, несмотря на архитектурные ограничения YOLOv8, изначально не предназначенной для градиентных методов атрибуции. Разработан эвристический алгоритм генерации карт внимания на основе пространственного распределения bounding boxes. Для каждого обнаруженного объекта создается тепловая карта, где пиксели внутри ограничивающей рамки получают значение, пропорциональное уверенности детекции, а окружающей области – затухающее значения по экспоненциальному закону, моделирующему гауссово распределение внимания, данные визуализации, преобразованные в псевдоцветное представление, позволяют анализировать фокусные области модели и выявлять потенциальные источники ошибок.

Отказоустойчивая система реализует трехуровневую иерархию доверия к предсказаниям модели, что особенно важно для критически важных применений, таких, как системы пожарной безопасности. Архитектура принятия решений разделяет все детекции на три категории:

- автоматически принимаемые при высокой уверенности
- отправляемые на экспертную проверку при промежуточных значениях
- отклоняемые как ненадежные при низкой уверенности

Данный подход позволяет создать гибридную систему, где рутинные случаи обрабатываются автоматически, а сложные и неоднозначные ситуации передаются человеку-эксперту для окончательного решения; процессный workflow включает инференс с расширенной чувствительностью, анализ максимальной уверенности по изображению, категоризацию и маршрутизацию результатов с формированием очереди экспертизы, содержащей полный контекст для принятия взвешенного решения.

Интеграционные аспекты системы обеспечивают формирование замкнутого цикла обработки данных компьютерного зрения, начиная с первичной разметки через интерактивный инструмент, обучения модели YOLOv8 [18, 19], посттренингового анализа для идентификации “слабых” мест, целевой доразметки сложных примеров и итеративного улучшения модели с валидацией через механизмы explainable AI и fail-safe. Научная новизна разработки заключается в практической реализации активного обучения для однопроходных детекторов, области менее исследованной по сравнению с двухпроходными архитектурами, а также в создании эвристических методов explainable AI для black-box моделей детекции, обеспечивающих баланс между интерпретируемостью и вычислительной эффективностью.

Практическая значимость системы наиболее выражена в задачах промышленного мониторинга и безопасности, особенно в детекции пожароопасных ситуаций в видимом и инфракрасном диапазонах. Инструменты оптимизированы для работы с несбалансированными наборами данных, где критические события редки, но требуют максимальной надежности обнаружения. Система активного обучения позволяет существенно сократить временные затраты на подготовку данных за счет концентрации усилий операторов на наиболее информативных примерах, а отказоустойчивые механизмы обеспечивают необходимый уровень надежности в системах автоматического принятия решений [20-23].

**4. Сравнительный анализ использования стандартного обучения и метода «Active learning».** Для оценки эффективности предложенного подхода был проведен сравнительный эксперимент между базовой моделью YOLOv8, обученной стандартным способом, и моделью, прошедшей итеративный цикл активного обучения. Эксперимент проводился на

специализированном датасете, содержащем 2457 изображений объектов теплоэнергетики. Данные были разделены на обучающую, валидационную и тестовую выборки в соотношении 70/15/15. Обе модели обучались при идентичных гиперпараметрах и условиях вычислительного эксперимента.

Эксперимент проводился на специализированном, подготовленном вручную, датасете и видеоданных с объектов теплоэнергетики, содержащем 2457 изображений в формате 640×640 пикселей. Датасет был разделен на обучающую (70%), валидационную (15%) и тестовую (15%) выборки. Для обеих моделей использовалась идентичная архитектура YOLOv8, идентичные гиперпараметры обучения (100 эпох, batch size=16, SGD optimizer) и условия аппаратного обеспечения (NVIDIA GeForce RTX 5070, 16 ГБ VRAM).

Качество моделей оценивалось по стандартным для задач детекции объектов метриками [15]:

- mAP@0.5 (mean Average Precision при IoU=0.5) – основная метрика качества детекции;
- mAP@0.5:0.95 – усредненная точность при различных порогах IoU от 0.5 до 0.95;
- Precision – доля верно-обнаруженных объектов среди всех обнаружений;
- Recall – доля верно-обнаруженных объектов среди всех существующих в данных;
- F1-Score – гармоническое среднее precision и recall.

После проведения валидации обеих моделей на идентичном тестовом наборе данных были получены количественные оценки их производительности [23-28]. Результаты сравнительного анализа представлены в таблице 1.

**Таблица 1.** Сравнительный анализ качества моделей детекции

Метрика	Базовая модель	Модель с активным обучением	Абсолютное улучшение	Относительное улучшение, %
mAP@0.5	0.9062	0.9420	+0.0358	+3.95
mAP@0.5:0.95	0.5137	0.6591	+0.1454	+28.32
Precision	0.8985	0.9052	+0.0067	+0.74
Recall	0.8461	0.9123	+0.0662	+7.82
F1-Score	0.8715	0.9087	+0.0372	+4.27

Анализ результатов демонстрирует устойчивое превосходство модели, дообученной с применением активного обучения, по всем ключевым метрикам. Наиболее значительный прирост наблюдается в показателе mAP@0.5:0.95 (+28,32%), что свидетельствует о существенном повышении качества детекции в сложных условиях при различных порогах перекрытия. Это указывает на эффективность метода в улучшении работы модели именно на тех примерах, которые представляют наибольшую трудность для классификации.

Не менее важным является рост полноты обнаружения (recall) на 7,82% при сохранении высокого уровня точности (precision), что для систем безопасности является критически значимым достижением. Улучшение F1-Score на 4,27% подтверждает сбалансированное повышение общего качества детекции. Полученные количественные результаты убедительно доказывают, что предложенный метод активного обучения позволяет целенаправленно улучшать модель за счёт итеративного добавления в обучение наиболее информативных сложных примеров.

Предложенный метод активного обучения решает проблемы технологического пара, высокотемпературных поверхностей за счет: целевой идентификации сложных случаев (алгоритм выявляет примеры, где модель демонстрирует минимальную уверенность, именно те ситуации, где визуальные признаки аварийной ситуации (дым, пламя) наиболее схожи с

нормальными технологическими процессами); адаптации к специфическому визуальному фону (итеративное добавление проблемных примеров позволяет научить модель различать технологический пар и дым, тепловое излучение оборудования и очаги возгорания, блики, отражения и пламя); компенсации дисбаланса классов, в условиях, где аварийные ситуации редки, но критически важны, активное обучение целенаправленно отбирает для доразметки именно те кадры, которые содержат слабовыраженные признаки опасности; интеграции экспертных знаний (разработанная система позволяет работать в гибридном режиме «машина-человек», это позволяет привлекать специалистов для доразметки наиболее неоднозначных случаев), что обеспечивает учет предметной специфики теплоэнергетических процессов.

**Заключение.** В работе предложен и экспериментально подтвержден комплексный подход к повышению точности и надежности систем компьютерного зрения для обеспечения безопасности объектов теплоэнергетики на основе методологии активного обучения. Адаптация Active Learning к однопроходным детекторам YOLOv8 и интеграция механизмов объяснимости и экспертной верификации позволили эффективно решить проблему дефицита специализированных размеченных данных. Полученные результаты демонстрируют, что целенаправленный отбор и доразметка наиболее информативных примеров обеспечивают существенное улучшение качества детекции пожароопасных ситуаций. Практическая значимость работы заключается в возможности внедрения предложенного подхода в системы промышленного мониторинга и раннего оповещения, где критически важны надежность и интерпретируемость автоматических решений. Перспективы дальнейших исследований связаны с расширением спектра обнаруживаемых аварийных событий и адаптацией подхода к другим классам промышленных объектов.

#### Список источников

1. Guang W., Yuan Y., Huang S. et al. Application of large AI models in safety and emergency management of the power industry in China. *Processes*, 2025, vol. 13, no. 8, p. 2569, DOI: 10.3390/pr13082569.
2. Xie J., Sun K., Lei X. Risk assessment method of power plant industrial control information security based on Bayesian attack graph. *Journal of Electrical Systems*, 2021, vol. 17, pp. 529-541.
3. Zhu G., Hu Y., Zhang X. et al. Applying deep learning and automated machine learning for enhanced state monitoring and health assessment of high-pressure heater in thermal power units. *Engineering Applications of Artificial Intelligence*, 2025, vol. 141, p. 109805, DOI: 10.1016/j.engappai.2024.109805.
4. Wang Y., Chung S.H. Artificial intelligence in safety-critical systems: a systematic review. *Industrial Management & Data Systems*, 2022, vol. 122, no. 2, pp. 442-470, DOI: 10.1108/IMDS-07-2021-0419.
5. Alotaibi N., Dursun S. Vision inspection of power lines with deep learning. *SPE Conference at Oman Petroleum & Energy Show*, 2024, DOI: 10.2118/218663-MS.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, pp. 436-444, DOI:10.1038/nature14539.
7. Рассел С., Норвиг П. Искусственный интеллект: современный подход – 3-е изд. / С. Рассел, П. Норвиг. – М.: Вильямс, 2021. – 1408 с.
8. Гудфеллоу Я. Глубокое обучение. – 2-е изд / Я. Гудфеллоу, И. Бенджио, А. Курвилль; пер. А.А. Слинкин. – М.: ДМК Пресс, 2018. – 652 с.
9. Мёрфи К. Машинное обучение: вероятностный подход / К. Мёрфи. – М.: ДМК Пресс, 2013. – 1067 с.
10. Гонсалес Р.С. Цифровая обработка изображений. – 3-е изд. / Р.С. Гонсалес, Р.Е. Вудс //– М.: Техносфера, 2012. – 1104 с.
11. Прэтт У. Цифровая обработка изображений / У. Прэтт. – М.: Мир, 2014. – 736 с.
12. Сзелиски Р. Компьютерное зрение: алгоритмы и приложения / Р. Сзелиски. – М.: Бином. Лаборатория знаний, 2016. – 812 с.
13. Дуда Р. Распознавание образов / Р. Дуда, П. Харт, Д. Сторк. – М.: Мир, 2010. – 680 с.
14. Gal Y., Islam R., Ghahramani Z. Deep Bayesian active learning with image data. In: D. Precup, Y.W. Teh (eds.). *Proceedings of the 34th International Conference on Machine Learning*. PMLR, 2017, vol. 70, pp. 1183-1192. Available at: <https://proceedings.mlr.press/v70/gal17a.html> (accessed: 05/15/2026).
15. Sener O., Savarese S. Active learning for convolutional neural networks: a core-set approach. *International Conference on Learning Representations (ICLR)*, 2018, DOI: 10.48550/arXiv.1708.00489.
16. Yoo D., Kweon I.S. Learning loss for active learning. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, DOI:10.48550/arXiv.1905.03677.

17. Redmon J., Farhadi A. YOLOv3: an incremental improvement. arXiv preprint, 2018, DOI: 10.48550/arXiv.1804.02767.
18. Ribeiro M.T., Singh S., Guestrin C. "Why should I trust you?" Explaining the predictions of any classifier. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'16), 2016, pp. 1135–1144, DOI: 10.1145/2939672.2939778.
19. Selvaraju R.R. et al. Grad-CAM: visual explanations from deep networks via gradient-based localization. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017, DOI: 10.48550/arXiv.1610.02391.
20. Raschka S., Mirjalili V. Python machine learning. 2nd ed. Birmingham, Packt Publishing Ltd., 2017.
21. Chollet F. Deep learning with Python. Manning Publications. Available at: <https://sourestdeds.github.io/pdf/Deep%20Learning%20with%20Python.pdf> (accessed: 05.16.2026).
22. Кулагина Л.В. Прототип системы раннего оповещения о пожаре на основе интеллектуального нейросетевого распознавания / Л.В. Кулагина, Э.А. Шефер // IV Международный Косыгинский Форум «Проблемы инженерных наук: формирование технологического суверенитета»: сборник научных трудов Международного научно-технического симпозиума «Современные инженерные проблемы ключевых отраслей экономики страны». – М.: РГУ им. А.Н. Косыгина, 2024. – С. 128-130. – EDN: DSEIXZ.
23. Кулагина Л.В. Подход к повышению надежности противопожарных технологий промышленного предприятия / Л.В. Кулагина, Э.А. Шефер // Сахаровские чтения 2024 года: экологические проблемы XXI века: материалы 24-й международной научной конференции. – Минск: ИВЦ Минфина Республики Беларусь, 2024. – С. 241-244. – DOI: 10.46646/SAKH-2024-2-241-244. – EDN: SOJANQ.
24. Кулагина Л.В. Совершенствование систем пожарной безопасности объектов теплоэнергетики / Л.В. Кулагина, Э.А. Шефер // Журнал Сибирского федерального университета. Серия: Техника и технологии, 2025. – Т. 18, № 6(127). – С. 778-789. – EDN: ZIOIEO.
25. Бычков А.Г., Киселёва Т.В., Маслова Е.В. Использование сверточных нейросетей для классификации изображений // Вестник Сибирского государственного индустриального университета, 2023, № 1(43), С. 39-49. – DOI: 10.57070/2304-4497-2023-1(43)-39-49.
26. Свидетельство о государственной регистрации программы для ЭВМ № 2024611904 Российская Федерация. Программный комплекс мониторинга теплового режима в производственных помещениях: № 2024610862: заявл. 22.01.2024: опублик. 25.01.2024 / Л.В. Кулагина, Э.А. Шефер; заявитель СФУ. – EDN: GESTOA.
27. Свидетельство о государственной регистрации программы для ЭВМ № 2023616496 Российская Федерация. Программа для прогнозирования качества воздуха на основе модели машинного обучения: № 2023611680: заявл. 01.02.2023: опублик. 28.03.2023 / Л.В. Кулагина; заявитель СФУ. – EDN: DMHFIE.
28. Свидетельство о государственной регистрации программы для ЭВМ № 2023665492 Российская Федерация. Программа для прогнозирования и мониторинга термоточек, в том числе техногенного происхождения (объекты теплоэнергетики): № 2023664095: заявл. 05.07.2023: опублик. 17.07.2023 / Л.В. Кулагина, И.В. Кириллова; заявитель СФУ. – EDN: JYMXXP.

*Кулагина Людмила Владимировна. Канд. техн. наук, доцент, доцент кафедры «Техносферная и экологическая безопасность» Политехнического института СФУ, AuthorID: 596975, SPIN: 1325-9320, ORCID: 0000-0003-4406-5060. [klvation@gmail.com](mailto:klvation@gmail.com). 660074, г. Красноярск, ул. Ак. Киренского, д. 26.*

*Шефер Эдуард Артурович. Аспирант кафедры «Техносферная и экологическая безопасность» Политехнического института СФУ, AuthorID: 1286852, SPIN: 1454-4289, ORCID: 0009-0000-3073-8821. [shefer.eduardov-119sp@list.ru](mailto:shefer.eduardov-119sp@list.ru). 660074, г. Красноярск, ул. Ак. Киренского, д. 26.*

---

UDC 621.311.25-047.36:004.032.26:004.932

DOI:10.25729/ESI.2026.42.2.009

## **Training a convolutional neural network model using the Active Learning method for monitoring the safety of thermal power plants**

**Ludmila V. Kulagina, Eduard A. Shefer**

Siberian Federal University, Russia, Krasnoyarsk, [shefer.eduardov-119sp@list.ru](mailto:shefer.eduardov-119sp@list.ru)

**Abstract.** Ensuring industrial safety at thermal power facilities requires effective and reliable early detection of potentially fire-hazardous and emergency situations. This task is complicated by specific operating conditions characterized by a wide range of operating modes, high levels of electromagnetic interference and vibration, and

often a limited amount of labeled data suitable for training and verifying monitoring and forecasting systems. The goal of this study is to develop and experimentally validate a comprehensive approach to improving the accuracy and reliability of computer vision systems for monitoring thermal power facility safety based on an active learning methodology. The primary methods utilized include convolutional neural network models for object detection based on the YOLOv8 architecture, a heuristic mechanism for selecting informative data based on an uncertainty metric, and tools for explainable artificial intelligence and fault-tolerant decision-making with expert participation. The scientific novelty of the work lies in the adaptation of Active Learning methods to single-pass detectors for industrial safety tasks, as well as in the integration of a cycle of targeted additional labeling of complex examples with mechanisms for interpretation and hybrid verification of results (which allows for minimizing labeling costs (due to a selective request for "complex" examples); prompt adaptation to new types of anomalies (e.g., non-standard leaks, local overheating)); whereas most publications on the safety of thermal power facilities use classical machine learning methods (SVM, random forests) or pre-trained CNNs without adaptation to the specifics of the industry. In the completed work, experimental studies on a specialized dataset of images of thermal power facilities showed that the use of active learning provides an increase in the mAP@0.5:0.95 indicator by 28.32% and an increase in the detection recall by 7.82% compared to standard learning. The obtained results confirm the potential of the proposed approach for practical application in monitoring and early warning systems capable of ensuring the timely detection of deviations from normal operating parameters of equipment and preventing the development of emergency scenarios.

**Keywords:** active learning, convolutional neural networks, YOLOv8, industrial safety, thermal power plants

### References

1. Guang W., Yuan Y., Huang S. et al. Application of large AI models in safety and emergency management of the power industry in China. *Processes*, 2025, vol. 13, no. 8, p. 2569, DOI: 10.3390/pr13082569.
2. Xie J., Sun K., Lei X. Risk assessment method of power plant industrial control information security based on Bayesian attack graph. *Journal of Electrical Systems*, 2021, vol. 17, pp. 529-541.
3. Zhu G., Hu Y., Zhang X. et al. Applying deep learning and automated machine learning for enhanced state monitoring and health assessment of high-pressure heater in thermal power units. *Engineering Applications of Artificial Intelligence*, 2025, vol. 141, p. 109805, DOI: 10.1016/j.engappai.2024.109805.
4. Wang Y., Chung S.H. Artificial intelligence in safety-critical systems: a systematic review. *Industrial Management & Data Systems*, 2022, vol. 122, no. 2, pp. 442-470, DOI: 10.1108/IMDS-07-2021-0419.
5. Alotaibi N., Dursun S. Vision inspection of power lines with deep learning. *SPE Conference at Oman Petroleum & Energy Show*, 2024, DOI: 10.2118/218663-MS.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, pp. 436-444, DOI:10.1038/nature14539.
7. Russell S., Norvig P. *Iskusstvennyy intellekt: sovremennyy podkhod [Artificial intelligence: a modern approach]*. 3rd ed. Moscow, Williams Publ., 2021, 1408 p.
8. Goodfellow I., Bengio Y., Courville A. *Glubokoye obucheniye [Deep learning]*. Trans. by A.A. Slinkin. 2nd ed. Moscow, DMK Press Publ., 2018, 652 p.
9. Murphy K. *Mashinnoye obucheniye: veroyatnostnyy podkhod [Machine learning: a probabilistic approach]*. Moscow, DMK Press Publ., 2013, 1067 p.
10. Gonzalez R.C., Woods R.E. *Tsifrovaya obrabotka izobrazheniy [Digital image processing]*. 3rd ed. Moscow, Tekhnosfera Publ., 2012, 1104 p.
11. Pratt W. *Tsifrovaya obrabotka izobrazheniy [Digital image processing]*. Moscow, Mir Publ., 2014, 736 p.
12. Szeliski R. *Kompyuternoye zreniye: algoritmy i prilozheniya [Computer vision: algorithms and applications]*. Moscow, Binom. Laboratory of Knowledge Publ., 2016, 812 p.
13. Duda R., Hart P., Stork D. *Raspoznavaniye obrazov [Pattern recognition]*. Moscow, Mir Publ., 2010, 680 p.
14. Gal Y., Islam R., Ghahramani Z. Deep Bayesian active learning with image data. In: *Proceedings of the 34th International Conference on Machine Learning*. PMLR, 2017, vol. 70, pp. 1183-1192 (accessed: 05/15/2026)
15. Sener O., Savarese S. Active learning for convolutional neural networks: a core-set approach. In: *Proceedings of the International Conference on Learning Representations (ICLR)*, 2018.
16. Yoo D., Kweon I.S. Learning loss for active learning. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, DOI:10.48550/arXiv.1905.03677.
17. Redmon J., Farhadi A. YOLOv3: an incremental improvement. *arXiv preprint*, 2018, DOI: 10.48550/arXiv.1804.02767.
18. Ribeiro M.T., Singh S., Guestrin C. "Why should I trust you?" Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'16)*, 2016, pp. 1135-1144, DOI: 10.1145/2939672.2939778.

19. Selvaraju R.R. et al. Grad-CAM: visual explanations from deep networks via gradient-based localization. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017, DOI: 10.48550/arXiv.1610.02391.
20. Raschka S., Mirjalili V. Python machine learning. 2nd ed. Birmingham, Packt Publishing Ltd., 2017.
21. Chollet F. Deep learning with Python. Manning Publications. Available at: <https://soureestdeeds.github.io/pdf/Deep%20Learning%20with%20Python.pdf> (accessed: 05.16.2026).
22. Kulagina L.V., Shefer E.A. Prototip sistemy rannego opoveshcheniya o pozhare na osnove intellektual'nogo neyrosetevogo raspoznavaniya [Prototype of an early fire warning system based on intelligent neural network recognition]. IV Mezhdunarodnyy Kosygin'skiy Forum "Problemy inzhenernykh nauk: formirovaniye tekhnologicheskogo suvereniteta": sbornik nauchnykh trudov Mezhdunarodnogo nauchno-tekhnicheskogo simpoziuma "Sovremennyye inzhenernyye problemy klyuchevykh otrasley ekonomiki strany" [IV International Kosygin Forum "Problems of Engineering Sciences: Formation of Technological Sovereignty": Proceedings of the International Scientific and Technical Symposium "Modern Engineering Problems of Key Sectors of the Country's Economy"]. Moscow, Kosygin University Publ., 2024, pp. 128-130, EDN: DSEIXZ.
23. Kulagina L.V., Shefer E.A. Podkhod k povysheniyu nadezhnosti protivopozharnykh tekhnologiy promyshlennogo predpriyatiya [An approach to improving the reliability of fire protection technologies at an industrial enterprise]. Sakharovskiye chteniya 2024 goda: ekologicheskiye problemy XXI veka: materialy 24-y mezhdunarodnoy nauchnoy konferentsii [Sakharov Readings 2024: Environmental Problems of the 21st Century: Proceedings of the 24th International Scientific Conference]. Minsk, Information and Computing Center of the Ministry of Finance of the Republic of Belarus Publ., 2024, pp. 241-244, DOI: 10.46646/SAKH-2024-2-241-244, EDN: SOJANQ.
24. Kulagina L.V., Shefer E.A. Sovershenstvovaniye sistem pozharной bezopasnosti ob'yektov teploenergetiki [Improving fire safety systems for thermal power facilities]. Zhurnal Sibir'skogo federal'nogo universiteta. Seriya: Tekhnika i tekhnologii [Journal of Siberian Federal University. Series: Engineering and Technologies], 2025, vol. 18, no. 6(127), pp. 778-789, EDN: ZIOIEO.
25. Bychkov A.G., Kiseleva T.V., Maslova E.V. Ispol'zovaniye svertochnykh neyrosetey dlya klassifikatsii izobrazheniy [Using convolutional neural networks for image classification]. Vestnik Sibir'skogo gosudarstvennogo industrial'nogo universiteta [Bulletin of Siberian State Industrial University], 2023, no. 1(43), pp. 39-49, DOI: 10.57070/2304-4497-2023-1(43)-39-49.
26. Kulagina L.V., Shefer E.A. Programmnyy kompleks monitoringa teplovogo rezhima v proizvodstvennykh pomeshcheniyakh [Software complex for monitoring thermal conditions in industrial premises]. State registration certificate of computer program No. 2024611904 Russian Federation: No. 2024610862, appl. 01.22.2024, publ. 01.25.2024, EDN: GESTOA.
27. Kulagina L.V. Programma dlya prognozirovaniya kachestva vozdukha na osnove modeli mashinnogo obucheniya [Program for air quality forecasting based on a machine learning model]. State registration certificate of computer program No. 2023616496 Russian Federation: No. 2023611680, appl. 02.01.2023, publ. 03.28.2023, EDN: DMHFIE.
28. Kulagina L.V., Kirillova I.V. Programma dlya prognozirovaniya i monitoringa termotochek, v tom chisle tekhnogennogo proiskhozhdeniya (ob'yekty teploenergetiki) [Program for forecasting and monitoring thermal points, including man-made ones (thermal power facilities)]. State registration certificate of computer program No. 2023665492 Russian Federation: No. 2023664095, appl. 07.05.2023, publ. 07.17.2023, EDN: JYMXXP.

**Kulagina Liudmila Vladimirovna.** PhD (candidate of technical sciences), Assistant Professor, Assistant Professor of the Chair «Technospheric and Ecological Safety» in SibFU, AuthorID: 596975, SPIN: 1325-9320, ORCID: 0000-0003-4406-5060. [klvation@gmail.com](mailto:klvation@gmail.com). 26 Kirenskogo str., Krasnoyarsk, Russia, 660074.

**Shefer Eduard Arturovich.** PhD student at the Chair «Technospheric and Ecological Safety» in SibFU. AuthorID: 1286852, SPIN: 1454-4289, ORCID: 0009-0000-3073-8821. [shefer.eduardov-119sp@list.ru](mailto:shefer.eduardov-119sp@list.ru). 26 Kirenskogo str., Krasnoyarsk, Russia, 660074.

Статья поступила в редакцию 21.05.2025; одобрена после рецензирования 04.10.2025; принята к публикации 10.02.2026.

The article was submitted 05/21/2025; approved after reviewing 10/04/2025; accepted for publication 02/10/2026.

УДК 681.323

DOI:10.25729/ESI.2026.42.2.010

## Методика построения цифровых двойников установок распределенной генерации с использованием нечетких моделей

Короткова Ксения Евгеньевна, Говорков Алексей Сергеевич

Иркутский национальный исследовательский технический университет,  
Россия, Иркутск, *kseniakorotkovs@yandex.ru*

**Аннотация.** В статье рассмотрены основные компоненты цифровых двойников и схема их взаимосвязи, особенности установок распределенной генерации и проблем, возникающих при их использовании. На сегодняшний день технология цифровых двойников активно используется в сфере промышленного производства. Цифровые двойники выступают в роли виртуальных аналогов физических объектов, групп объектов или процессов. Они представляют собой сложные программные решения, основанные на большом объеме данных и синтезе технологий искусственного интеллекта, машинного обучения и специализированного ПО, что позволяет создавать динамичные цифровые модели, способные к "живому" взаимодействию и адаптации. В статье представлена методика построения цифровых двойников установок распределенной генерации, применение которых способствует оптимизации процессов проектирования, эксплуатации и мониторинга электроэнергетических систем. Методика излагается на примере турбогенераторной установки и включает этапы: сбор данных о физическом объекте, моделирование турбогенераторной установки, сравнение экспериментальных данных и отклика нечеткой модели. Научная новизна исследования заключается в разработке гибридного подхода, сочетающего нейронные сети, систему нечеткого логического вывода и генетический алгоритм; в выявлении минимального среднеквадратичного отклонения (СКО) отклика модели от экспериментальных данных; определении оптимального количества правил в нечеткой системе (144 правила), а также в установлении зависимости между точностью модели и вычислительными затратами. Практическая значимость результатов состоит в возможности применения разработанной методики для оптимизации работы установок распределенной генерации, повышения надежности электроснабжения и эффективности управления электроэнергетическими системами. Предложенный подход позволяет создавать точные цифровые модели, способные адаптироваться к изменяющимся условиям эксплуатации. Результаты исследования могут быть использованы при разработке новых энергетических систем, модернизации существующих объектов и внедрении технологий Smart Grids. Предложенный подход открывает новые перспективы для развития энергоэффективных и надежных систем электроснабжения.

**Ключевые слова:** цифровые двойники, установки распределенной генерации, Smart Grids

**Цитирование:** Короткова К.Е. Методика построения цифровых двойников установок распределенной генерации с использованием нечетких моделей / К.Е. Короткова, А.С. Говорков // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 128-142. – DOI:10.25729/ESI.2026.42.2.010.

**Введение.** Цифровые двойники (ЦД) – инновационная технологическая концепция, созданная для улучшения работы физических прототипов, производственного оборудования, сложных систем и отдельных процессов [1]. Концепция была впервые представлена в 2003 году и получила широкое признание благодаря работе профессора и заместителя директора Центра управления жизненным циклом и инновациями Технологического института Флориды Майкла Гривса «Цифровые двойники: превосходство в производстве на основе виртуального прототипа завода» ЦД представляет собой гибридную модель, которая сочетает физические и цифровые компоненты, разрабатывается с учетом уникальных потребностей производства и служит для предсказания неисправностей оборудования, подготовки графиков ремонта, снижение затрат на обслуживание и предотвращение неожиданных простоев.

Надежность электроснабжения достигается за счет использования установок распределенной генерации (УРГ), включая установки, основанные на возобновляемых источниках энергии (ВИЭ). Разработка методик создания ЦД для УРГ является актуальной, так как это позволит получить полные математические (цифровые) модели систем

электроснабжения, которые помогут решать задачи оптимального управления УРГ, их размещения, планирования ремонтов, диагностики электрооборудования и многое другое.

Одной из ведущих отраслей экономики является энергетика. Стремительное внедрение новейших технологий в эту отрасль усложняет обеспечение устойчивой работы энергосистем. В связи с большими объемами обрабатываемой и хранящейся информации, быстрым протеканием процессов и комплексным анализом данных оперативно-диспетчерское управление необходимо постоянно совершенствовать [2], учитывая цифровизацию структуры электроэнергетики и внедрение Интернета вещей с целью реализации концепции виртуальных электростанций при управлении множеством УРГ.

## **1. Теоретические основы цифровых двойников.**

**1.1. Основные компоненты цифрового двойника.** Основными компонентами цифрового двойника являются:

1. Физическая модель с точным описанием ее структуры и компонентов, а также физических процессов, происходящих внутри объекта.
2. Данные, полученные от систем сбора данных. Они обеспечивают мониторинг состояния установки и показывают данные о производительности, состоянии оборудования и окружающей среде.
3. Алгоритмы для обработки и анализа собранных данных и математические (цифровые) модели для симуляции работы установки в различных условиях и сценариях.
4. Интерфейс визуализации данных и результатов анализа, обеспечивающий удобный доступ к информации для операторов и инженеров, а также возможность управлять цифровым двойником и получать необходимые графики и отчеты.
5. Системы управления установками, позволяющие использовать данные цифрового двойника для оптимизации работы и принятия решений и автоматизации процессов управления.
6. История объекта, позволяющая оценить и показать работу объекта в прошлом, и на основании этих данных улучшить модели и алгоритмы.
7. Симуляционные модели, позволяющие проводить виртуальные испытания и симуляции различных сценариев работы установки и оценивать влияние изменений в конфигурации или условиях эксплуатации на производительность.
8. Обратная связь и обучение, используемые для обновления и улучшения цифрового двойника на основе новых данных и результатов анализа, при непрерывном обучении и адаптации модели к изменяющимся условиям.

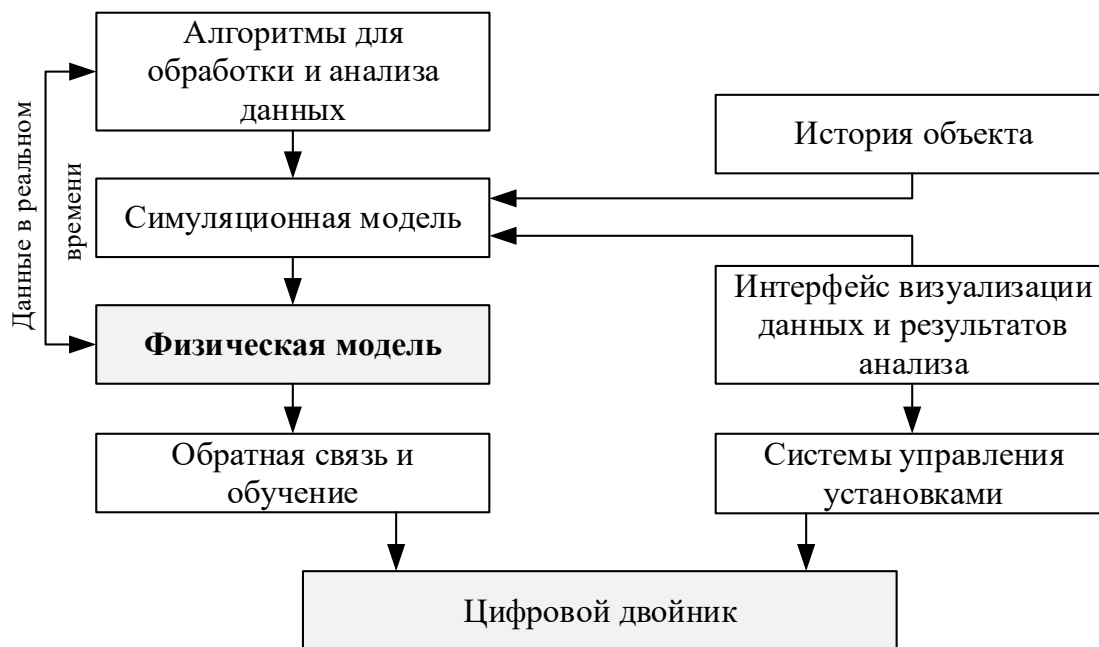
Эти компоненты работают в совокупности, создавая динамическую и адаптивную модель, которая помогает в управлении, оптимизации и прогнозировании работы установок распределенной генерации. Графическое представление и взаимосвязи компонентов цифрового двойника иллюстрируются рис. 1.

**2. Распределенная генерация: особенности и вызовы.** Установки распределенной генерации представляют собой системы, которые производят электроэнергию вблизи места потребления, а не на крупных централизованных электростанциях. Эти установки могут использовать различные источники энергии, включая возобновляемые (солнечные панели, ветряные турбины и др.) и традиционные (дизель-генераторные установки).

Необходимость использования УРГ обусловлена несколькими ключевыми факторами, которые становятся все более актуальными. Во-первых, УРГ позволяют значительно сократить потери электроэнергии, так как производство происходит вблизи мест потребления. Это минимизирует расстояние, на которое энергия должна быть передана, что особенно важно

в условиях растущего спроса на электроэнергию и необходимости повышения эффективности систем.

Во-вторых, распределенная генерация способствует интеграции возобновляемых источников энергии, таких, как солнечные и ветровые установки, что позволяет снизить углеродный след и поддерживать устойчивое развитие, поэтому становится критически важным в условиях глобальных климатических изменений.



**Рис. 1.** Графическое представление компонентов цифрового двойника

Кроме того, УРГ обеспечивают гибкость и модульность энергетических систем, позволяя адаптироваться к изменяющимся потребностям и условиям рынка. Это особенно важно для регионов с различными уровнями потребления и доступностью ресурсов. УРГ также помогают разгружать централизованные электросети в пиковые часы, повышая надежность и стабильность электроснабжения.

Не менее важным является и экономический аспект: УРГ могут снижать затраты на электроэнергию для потребителей, а также создавать новые рабочие места в сфере возобновляемой энергетики. Однако, несмотря на все преимущества, использование УРГ связано с определенными вызовами, такими, как необходимость интеграции в существующие сети, управление непредсказуемым производством энергии и соблюдение нормативных требований. Тем не менее, преодоление этих трудностей открывает новые горизонты для устойчивого и эффективного энергетического будущего, делая установки распределенной генерации важным элементом в трансформации энергетической системы.

Ниже рассмотрим более подробно особенности и проблемы использования установок распределенной генерации.

## 2.1. Особенности УРГ:

2.1.1. Близость установок распределенной генерации к местам потребления электроэнергии играет ключевую роль в повышении эффективности энергетических систем. Когда УРГ находятся рядом с потребителями, это позволяет значительно снизить потери энергии, которые неизбежно возникают при передаче электроэнергии на большие расстояния. В традиционных централизованных системах, где электростанции расположены далеко от потребителей, происходит значительное количество потерь из-за сопротивления проводников и других факторов, связанных с транспортировкой электроэнергии. Эти потери могут достигать значительных значений, особенно в условиях высоких нагрузок.

Расположение УРГ рядом с потребителями не только снижает потери при передаче электроэнергии, но и способствует повышению общей эффективности энергетической системы. Это создает условия для более устойчивого и надежного энергоснабжения, что особенно важно в условиях растущего спроса на электроэнергию и необходимости перехода на экологически чистые источники энергии. В конечном итоге, такая близость не только улучшает качество энергоснабжения, но и способствует более рациональному использованию ресурсов и снижению воздействия на окружающую среду.

2.1.2. Гибкость и модульность УРГ являются одними из их наиболее значительных преимуществ, позволяя им адаптироваться к изменяющимся условиям рынка и потребностям пользователей. УРГ могут быть спроектированы и установлены в компактных масштабах, то есть легче наращивать или уменьшать их мощность в зависимости от текущих потребностей в энергии, что делает их идеальными для динамично развивающихся регионов или для мест с переменным спросом на электроэнергию.

Когда спрос на электроэнергию увеличивается, УРГ могут быть быстро расширены за счет добавления новых модулей или установки дополнительных единиц генерации. Это позволяет обеспечить необходимый уровень энергоснабжения без значительных затрат на инфраструктуру и без необходимости ждать завершения строительства крупных электростанций.

Кроме того, модульность УРГ создает возможность комбинировать разные технологии в зависимости от доступных ресурсов и предпочтений потребителей. Такой подход не только повышает общую эффективность системы, но и способствует более рациональному использованию природных ресурсов.

Таким образом, гибкость и модульность установок распределенной генерации обеспечивают их способность эффективно функционировать в условиях неопределенности и динамичности современного энергетического рынка. Возможность быстро масштабировать и адаптировать установку в зависимости от потребностей пользователей и изменения рыночной ситуации делает УРГ важным инструментом для достижения устойчивого и надежного энергоснабжения в будущем.

2.1.3. Использование возобновляемых источников энергии. Многие УРГ основаны на ВИЭ, что значительно способствует снижению углеродного следа, поскольку ВИЭ производят электроэнергию без выбросов углекислого газа и других парниковых газов, которые способствуют глобальному потеплению. Переход на УРГ, использующие ВИЭ, поддерживает устойчивое развитие, позволяя странам и регионам уменьшать свою зависимость от ископаемых видов топлива, которые истощаются и наносят вред окружающей среде.

Использование ВИЭ в УРГ также способствует диверсификации энергетических источников, что повышает энергетическую безопасность. Это особенно важно в условиях изменения климата и нестабильности на глобальных энергетических рынках.

Кроме того, развитие УРГ на основе ВИЭ способствует внедрению инновационных технологий и повышению уровня осведомленности о важности устойчивого развития среди населения. Люди становятся более вовлеченными в процессы, связанные с энергетикой, и начинают осознавать свою роль в сохранении окружающей среды. Это может привести к росту интереса к энергосбережению, использованию чистых технологий и внедрению новых практик, направленных на снижение потребления энергии.

2.1.4. Снижение нагрузки на централизованные сети. Установки распределенной генерации играют важную роль в разгрузке основных электросетей, особенно в периоды пикового потребления электроэнергии. Так же УРГ могут использоваться для хранения избыточной энергии, например, в период низкого потребления. Ветровые или солнечные

установки могут генерировать больше энергии, чем требуется в данный момент, и эта избыточная энергия может быть сохранена для использования в будущем. Таким образом, УРГ не только способствуют разгрузке сетей в пиковые часы, но и помогают оптимизировать использование ресурсов, что, в свою очередь, делает энергетическую систему более устойчивой и эффективной.

Внедрение УРГ способствует развитию умных сетей, которые могут управлять потоками энергии более гибко и эффективно. Умные сети используют современные технологии для мониторинга и управления потреблением, что позволяет интегрировать УРГ в общую энергетическую систему. Это создает возможности для более рационального распределения ресурсов и повышения общей эффективности, что в конечном итоге приводит к снижению затрат для потребителей и улучшению качества электроснабжения.

УРГ играют ключевую роль в обеспечении надежности и устойчивости электроснабжения, особенно в периоды пикового потребления, разгружая основные электросети и способствуя более эффективному использованию энергетических ресурсов. Это делает их важным элементом и необходимым шагом к созданию более устойчивой и безопасной энергетической системы.

**2.1.5 Доступ к новым технологиям.** Внедрение современных технологий, таких, как системы хранения энергии и интеллектуальные сети (Smart Grid), значительно улучшает управление распределенной генерацией и способствует созданию более эффективной и надежной энергетической системы [3].

Интеллектуальные сети, в свою очередь, представляют собой интегрированную систему, которая использует современные информационные и коммуникационные технологии для мониторинга и управления распределением электроэнергии. Они позволяют более точно отслеживать потребление и генерируемую энергию в реальном времени, что обеспечивает более эффективное распределение ресурсов. Интеллектуальные сети способны автоматически регулировать потоки энергии, оптимизируя работу УРГ и снижая вероятность перегрузок. Благодаря этому потребители могут получать информацию о своем потреблении и, при необходимости, адаптировать его, что способствует более рациональному использованию ресурсов.

## **2.2. Проблемы, возникающие при использовании УРГ:**

**2.2.1 Интеграция УРГ в существующую инфраструктуру электросетей** представляет собой сложную задачу, обусловленную множеством факторов, включая различия в стандартах и технологиях. Одной из основных проблем является несовместимость различных систем, которые могут использоваться для управления и распределения электроэнергии.

Разнообразие технологий, применяемых в УРГ, также создает проблемы. Разные типы генераторов имеют различные характеристики и требования к подключению. Это требует разработки унифицированных стандартов и протоколов, чтобы обеспечить совместимость и эффективное взаимодействие всех компонентов системы.

Еще одной важной задачей является необходимость модернизации существующей инфраструктуры. Многие электросети были построены десятилетия назад и не предназначены для работы с распределенными источниками энергии, которые могут генерировать электроэнергию в разных точках сети, что требует значительных инвестиций в их модернизацию.

Различные страны и регионы могут иметь свои собственные правила и нормы, касающиеся подключения УРГ к электросетям. Это может усложнить процесс интеграции и потребовать от операторов сетей учета множества различных требований и стандартов.

Несмотря на эти проблемы, интеграция УРГ в существующую инфраструктуру электросетей является необходимым шагом для создания более устойчивой и эффективной энергетической системы. Разработка новых технологий, унификация стандартов и активное сотрудничество между государственными органами, энергетическими компаниями и производителями оборудования могут значительно облегчить этот процесс. В конечном итоге, успешная интеграция УРГ не только повысит надежность электроснабжения, но и будет способствовать более широкому использованию возобновляемых источников энергии, что имеет критическое значение для достижения целей по снижению углеродных выбросов и борьбе с изменением климата.

2.2.2. Непредсказуемость производства. Производство электроэнергии из возобновляемых источников, таких, как солнечная и ветровая энергия, подвержено значительным колебаниям, зависящим от погодных условий. Это создает определенные проблемы для управления спросом и предложением в энергетической системе, так как потребление электроэнергии часто не совпадает с периодами ее генерации.

Одним из ключевых решений для управления этими колебаниями является использование систем хранения энергии, таких, как аккумуляторы, которые позволяют накапливать избыточную электроэнергию в периоды ее высокого производства и использовать ее в моменты, когда генерация снижается. Кроме того, современные интеллектуальные сети (Smart Grids) помогают оптимизировать распределение энергии, обеспечивая более точное управление потоками в реальном времени. Программы управления спросом играют важную роль, позволяя потребителям адаптировать свое потребление в зависимости от доступности энергии и ценовых сигналов. Все эти меры способствуют созданию более устойчивой и адаптивной энергетической системы, способной эффективно интегрировать возобновляемые источники энергии и минимизировать влияние их колебаний на стабильность электроснабжения.

2.2.3. Необходимость соответствия различным нормативным актам и стандартам может стать серьезным препятствием для внедрения УРГ. Компании и организации, стремящиеся интегрировать новые технологии, часто сталкиваются с высокими требованиями, которые варьируются в зависимости от региона и типа энергетической системы. Эти нормативные акты могут касаться не только технических аспектов, таких, как безопасность и эффективность оборудования, но и экологических норм, которые регулируют воздействие на окружающую среду. Процесс получения необходимых разрешений и лицензий может быть длительным и затратным, что замедляет темпы внедрения инновационных решений. Более того, отсутствие четких и унифицированных стандартов может привести к неопределенности и рискам для инвесторов, что также сдерживает развитие УРГ и их интеграцию в существующие энергетические системы. Для успешного внедрения УРГ необходимо не только разработать эффективные технологии, но и создать благоприятные условия, включая упрощение нормативного регулирования и поддержку со стороны государственных органов.

2.2.4. Экономическая целесообразность: Первоначальные инвестиции в установку и обслуживание УРГ могут быть значительными, что требует тщательного анализа рентабельности перед принятием решения о внедрении таких систем. Поэтому важно проводить детальный анализ, учитывающий не только первоначальные расходы, но и потенциальные долгосрочные выгоды, такие, как экономия на операционных затратах, снижение зависимости от традиционных источников энергии и потенциальные налоговые льготы или субсидии. Также следует учитывать возможные изменения в ценах на энергоресурсы и экологические преимущества, которые могут повысить

конкурентоспособность бизнеса. Только взвешенная оценка всех этих факторов поможет определить целесообразность инвестиций в УРГ и их влияние на финансовую устойчивость компании в будущем.

2.2.5 Технологические риски. Быстрое развитие технологий в сфере УРГ может привести к тому, что существующие установки становятся устаревшими всего за несколько лет после их внедрения. Это явление требует от компаний постоянного обновления и модернизации своих систем для поддержания конкурентоспособности, и эффективности. Новые разработки часто предлагают более высокую производительность, улучшенную эффективность и сниженные эксплуатационные расходы, что делает старые установки менее привлекательными в долгосрочной перспективе. В результате организации, которые не успевают адаптироваться к быстро меняющимся условиям рынка, могут столкнуться с риском утраты конкурентных преимуществ и снижения прибыльности. Кроме того, необходимость регулярного обновления технологий может потребовать значительных финансовых вложений, что создает дополнительную нагрузку на бюджеты компаний. Важно также учитывать, что внедрение новых технологий может требовать дополнительных затрат на обучение персонала и изменение бизнес-процессов, что также усложняет задачу. Таким образом, для успешного функционирования в условиях стремительных технологических изменений компаниям необходимо не только инвестировать в новые системы, но и разрабатывать стратегию управления инновациями, которая позволит эффективно интегрировать новые решения и минимизировать риски, связанные с устареванием оборудования

2.2.6. Проблемы с хранением энергии: Эффективное хранение энергии, произведенной УРГ, представляет собой одну из ключевых задач в сфере энергетики, особенно для возобновляемых источников энергии, эти источники энергии обладают природным непостоянством. Поэтому для обеспечения стабильного и надежного электроснабжения необходимо разработать эффективные решения для хранения избыточной энергии, которая может быть использована в периоды низкой выработки.

Эффективное хранение энергии также связано с необходимостью интеграции современных технологий управления и распределения энергии. Умные сети способны оптимизировать потребление и распределение энергии, позволяя более эффективно использовать накопленную энергию. Это не только улучшает надежность электроснабжения, но и способствует снижению углеродного следа, что важно для достижения целей устойчивого развития. Таким образом, дальнейшие инвестиции и исследования в области хранения энергии и управления энергосистемами являются ключевыми для успешной интеграции ВИЭ в общую энергетическую инфраструктуру

Установки распределенной генерации имеют потенциал значительно изменить ландшафт энергетической отрасли, способствуя более устойчивому и эффективному производству электроэнергии. Однако для достижения этого потенциала необходимо решить ряд проблем, связанных с интеграцией, экономикой и технологическими аспектами.

**3. Методика построения цифровых двойников для установок распределенной генерации.** Методика построения цифровых двойников для УРГ представляет собой комплексный процесс, который включает в себя несколько ключевых этапов. Цифровой двойник – это виртуальная модель физического объекта или системы, которая позволяет отслеживать его состояние, производительность и поведение в реальном времени [4]. Для создания цифрового двойника УРГ необходимо учитывать, как физические, так и функциональные характеристики системы.


Цифровой двойник УРГ можно описать формулой:

$$\text{УРГ} = \{P, F, n\}, \quad (1)$$

где  $P$  – ключевые параметры нечеткой модели УРГ;  $F$  – оптимальные настройки нечеткой модели УРГ,  $n$  – КПД УРГ.

**3.1. Сбор данных о физическом объекте.** Первым этапом построения ЦД УРГ является сбор данных о физическом объекте.

Физическая модель УРГ представлена на рисунке 2 [5].



**Рис. 2.** Фото физической модели УРГ: Т – турбина; ОВ – обмотка возбуждения; BR – датчик угловых перемещений

Нечеткие модели строились парами, по данным, указанным в Таблице 1.

**Таблица 1.** Данные «вход-выход» нечеткой модели УРГ

№	Вход	Выход
1	$P_m$ - механическая мощность	$\omega_m$ – скорость вращения ротора
2	$U_f$ – напряжение возбуждения	$U_g$ – напряжение генератора
3	$P_m$ - механическая мощность	$P_g$ - активная мощность генератора
4	$U_f$ – напряжение возбуждения	$Q_g$ - реактивная мощность генератора
5	$V_{asr}$ – регулятор скорости	$P_m$ – механическая мощность
6	$V_{avr}$ – регулятор возбуждения	$U_f$ – напряжение возбуждения
7	$P_m$ - механическая мощность $U_f$ – напряжение возбуждения	$I_g$ - ток генератора

Установкой распределенной генерации в работе является синхронный генератор малой мощности, ротор которого приводится во вращение с помощью тепловой турбины [6-10].

**3.2. Моделирование турбогенераторной установки.** На втором этапе осуществляется моделирование системы с использованием подходящих программных инструментов и алгоритмов. Этот этап может включать в себя математическое моделирование, которое позволяет описать динамику процессов в установке, а также использование методов машинного обучения для анализа больших объемов данных и предсказания поведения системы. В результате создается виртуальная модель, которая отражает реальное состояние установки и может быть использована для мониторинга, анализа и оптимизации работы установки распределенной генерации.

Для изучения реакции УРГ была построена модель и выполнено сравнение ключевых параметров исходной системы и полученной модели [11-13].

Моделирование осуществлялось применительно к турбогенераторной установке, работающей на выделенную нагрузку. Схема модели исследуемой системы в MatLab, выполненной с помощью пакетов Simulink и SimPowerSystems, представлена на рис. 3 [14].




Рис. 3. Схема исследуемой модели УРГ в MatLab

Экспериментальные данные получены в результате работы УРГ в режиме, который может быть описан следующим алгоритмом:

1. Работа турбогенератора на номинальную нагрузку  $2,5+j1,8$  МВ·А;
2. Подключение через 10 секунд дополнительной нагрузки на  $0,6+j0,3$  МВ·А;
3. Подключаемый потребитель подключается через линию электропередачи длиной 1,8 км (блок Line на рис.4).

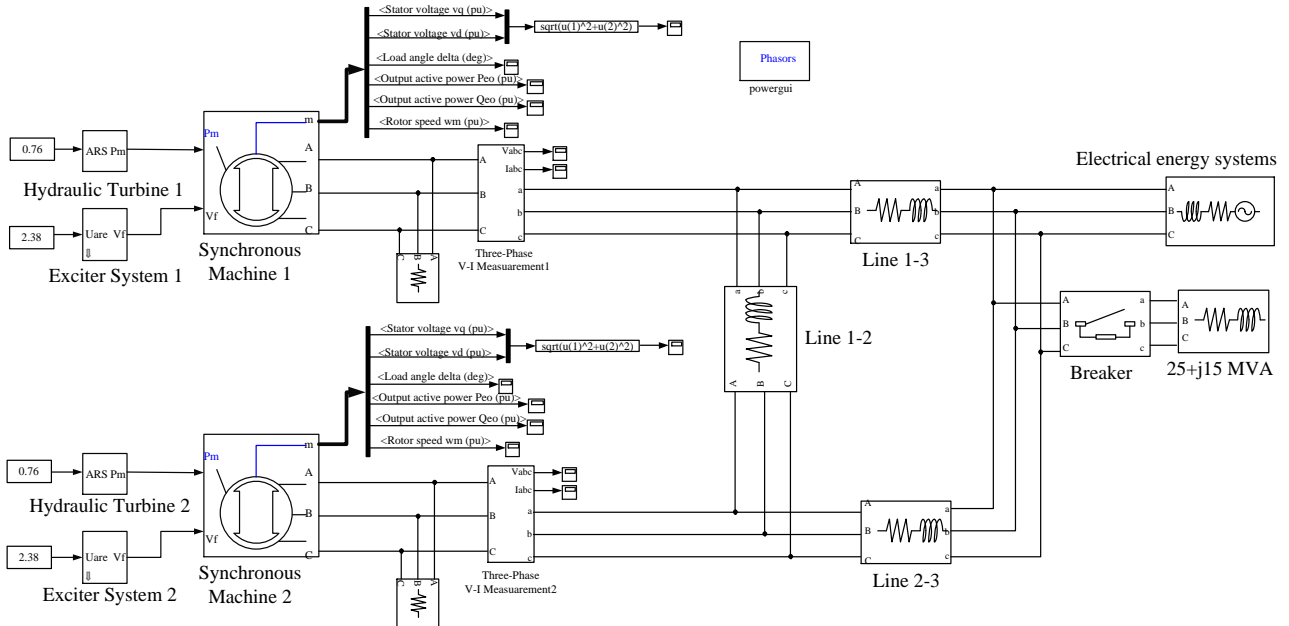


Рис. 4. Схема модели исследуемой сети в MATLAB

### 3.3. Сравнение экспериментальных данных и отклика нечеткой модели.


Заключительным этапом является сравнение экспериментальных данных и отклика нечеткой модели внедрения системы мониторинга и управления, которая позволит в реальном времени отслеживать состояние установки и вносить коррективы в ее работу на основе данных, получаемых от цифрового двойника. Это обеспечит более высокую эффективность, надежность и устойчивость работы установок распределенной генерации.

Моделирование выполнялось применительно к схеме электроснабжения, в двух узлах которой подключены мини-ГЭС номинальной мощностью по 24 МВт, работающие на базе синхронных генераторов, а третий узел имеет связь с электроэнергетической системой большой мощности. Полная схема модели исследуемой сети в MATLAB, в которой учитываются описываемые выше УРГ с автоматическим регулятором возбуждения (АРВ), автоматическим регулятором скорости (АРС) и нечеткими контроллерами, изменяющими настройки регуляторов, представлена на рис. 4.

На рис. 5 представлены результаты сравнения экспериментальных данных «вход-выход» турбины с обученной оптимизированной нечеткой моделью, построенной с помощью 144 правил типа ЕСЛИ-ТО. Однако для обучения и оптимизации такой продукционной модели требуется мощный вычислительный ресурс. В дальнейшем, используя полученные нечеткие модели для различных режимов работы, можно будет оптимизировать количество нечетких правил. Таким образом, предлагаемый метод построения оптимизированной нечеткой модели отдельного элемента цифрового двойника УРГ дает приемлемые результаты при сравнении с экспериментальными данными.

В качестве средства оценки близости нечеткой модели с экспериментальными данными было принято среднеквадратичное отклонение (СКО), которое в идеальных условиях должно быть близко к нулю.

В данной работе расчет СКО был выполнен при помощи MatLab и применительно к паре переменных «вход-выход» Среднеквадратичное отклонение отклика нечеткой модели от экспериментальных данных, используемых при обучении, составило 0,0126 [15].




**Рис. 5.** Результаты сравнения экспериментальных данных и отклика нечеткой модели:

1 – экспериментальные данные; 2 – оптимизированная обученная нечеткая модель (144 правила)

При построении нечеткой модели использовался пакет Fuzzy Logic Toolbox программной среды MatLab, включающий различные алгоритмы нечеткого логического вывода типа Сугено и Мамдани. При использовании алгоритма Сугено применялись два метода дефаззификации: wtaver (weighted average) – метод взвешенного среднего; wtsun – взвешенное суммарное значение [11].


Применение алгоритма типа Сугено было реализовано с помощью функции genfis2, которая генерирует систему нечеткого логического вывода с использованием субтрактивной кластеризации даны. По результатам экспериментов с использованием алгоритма нечеткого логического вывода типа Сугено (or – prod, and – max, метод дефаззификации – wtsun) была

получена модель «вход-выход», определяющая скорость вращения ротора генератора  $\omega_m$ , и дающая наименьшее среднеквадратичное отклонение (СКО) от экспериментальных данных 0,11%. Результаты сравнения экспериментальных данных и полученной нечеткой модели показаны на рис. 6.



**Рис. 6.** Сравнение экспериментальных данных (1) и отклика нечеткой модели (2)

Также было проведено сравнение данных при изменении радиуса кластеров в функции *genfis2*, генерирующей систему нечеткого логического вывода (тип Сугено: *or* – *probor*, *and* – *prod*, метод дефаззификации – *wtaver*, значение радиуса кластеров 0,8). Полученная модель давала СКО от экспериментальных данных 0,12%. Результаты сравнения показаны на рис.7.



**Рис. 7.** Сравнение экспериментальных данных (1) и отклика нечеткой модели (2) при радиусе кластеров 0,8

Эксперименты показали, что уменьшение значения радиуса кластеров в функции *genfis2* увеличивает СКО отклика нечеткой модели от экспериментальных данных. Таким образом, оптимальным в данном случае является значение радиуса кластеров, близкое к 1.

Для исследования работы алгоритма нечеткого вывода типа Мамдани была использована функция *genfis3*, применяющая кластеризацию нечетких *s*-средних. Данная функция имеет пять встроенных методов дефаззификации; формулы для расчетов представленных методов дефаззификации приведены в специальной литературе, например, в [16].

В процессе построения модели ЦД турбогенераторной УРГ использовался метод формирования нечеткой модели, основанный на экспериментальных данных в следующих режимах:

- подключение дополнительного потребителя с заданной нагрузкой;
- возникновение трёхфазного КЗ на шинах потребителя и его отключение релейной защитой через 0,5 с.

Для нахождения оптимальных настроек ЦД и получения параметров построения нечеткой модели, были рассмотрены различные комбинации моделей:

Функция реализации алгоритма нечеткого логического вывода:

Anfis – позволяет получить нечеткую систему вывода Сугено одного выхода и определить системные параметры при помощи данных ввода/вывода. Для автоматической генерации НСВ используется метод разделения сетки. Алгоритм работы метода обучения набора данных может быть описан как комбинация методов наименьших квадратов и методов градиентного спуска.


Genfis3 – для получения нечеткой системы вывода используется принцип нечетких средних значений, извлекающий некоторые ряды правил. Для работы данной функции необходим отдельный набор входных и выходных данных, что может послужить существенным ограничением.

Объединение нечетких систем вывода данных, полученных при моделировании работы УРГ в различных режимах работы:

- в переходном режиме, вызванном подключением дополнительной нагрузки;
- в режиме трехфазного КЗ.
- Изменение диапазона входных и выходных переменных нечетких систем вывода, построенных на данных при подключении нагрузки, на диапазон данных режима КЗ и наоборот.

Методология эксперимента включала варьирование количества правил в нечеткой системе вывода в интервале от 10 до 400. Конфигурация с 1000 правил, несмотря на предварительное тестирование, была исключена из дальнейшего рассмотрения вследствие чрезмерной длительности процесса моделирования. Для генерации систем нечеткого вывода применялась функция **genfis3**. Исходные данные для обучения были получены путем моделирования режима короткого замыкания (КЗ) в УРГ. Целью построения модели был нечеткий вывод параметров, характеризующих подключение дополнительной нагрузки. Для максимальной исследуемой базы (400 правил) были заданы диапазоны изменения соответствующих входных (КЗ) и выходных (нагрузка) переменных.

СКО отклика нечеткой модели от экспериментальных данных составило  $7,08 \cdot 10^{-5}$ . Результаты сравнения экспериментальных данных и полученной нечеткой модели показаны на рис. 8.



**Рис. 8.** Сравнение экспериментальных данных (1) и данных, полученных в результате моделирования (2)

**Заключение.** В ходе исследования подтверждена высокая эффективность применения гибридного подхода, основанного на использовании нейронных сетей, системы нечеткого логического вывода и генетического алгоритма для построения цифровых моделей по экспериментальным данным. Установлено, что для сложных переходных процессов формирование и оптимизация нечетких моделей с обширными базами правил (144 и более) сопряжены со значительными вычислительными затратами. Результаты экспериментов демонстрируют компромиссный характер зависимости: увеличение числа правил снижает среднеквадратичное отклонение (СКО) модели от экспериментальных данных, но пропорционально увеличивает время ее построения. Таким образом, перспективным направлением дальнейших исследований является разработка методов оптимизации размера базы правил для достижения приемлемого баланса между точностью модели (СКО) и вычислительной эффективностью.

#### Список источников

1. Grieves M.W. Digital twin: manufacturing excellence through virtual factory replication. LLC, 2014, 7 p.
2. Мухлина Е.С. Будущее цифровых двойников в энергетике / Е.С. Мухлина, А.Г. Логачева // Диспетчеризация и управление в электроэнергетике: материалы XV Всероссийской открытой молодежной научно-практической конференции. – Казань: КГЭУ, 2020. – С. 354-356.
3. Jia L., Li Z., Hu Z. Applications of the internet of things in renewable power systems: a survey. *Energies*, 2024, vol. 17, no. 16, p. 4160, DOI: 10.3390/en17164160.
4. Boháčik A., Fudjak R. The problem of integrating digital twins into electro-energetic control systems. *Smart Cities*, 2024, vol. 7, no. 5, pp. 2702-2740, DOI: 10.3390/smartcities7050105.
5. Bulatov Yu., Kryukov A., Batuhtin A. et al. Digital twin formation method for distributed generation plants of cyber–physical power supply systems. *Mathematics*, 2022, vol. 10, no. 16, p. 2886, DOI: 10.3390/math10162886.
6. Bulatov Yu.N., Korotkova K.E. Application of digital twin technologies in the energy sector. *Proceedings of the Bratsk State University. Series: Natural and Engineering Sciences*, 2012, vol. 1, pp. 103-112.
7. Kryukov A.V., Kargapol'tsev S.K., Bulatov Yu.N. et al. Intelligent control of the regulators adjustment of the distributed generation installation. *Far East Journal of Electronics and Communications*, 2017, vol. 17, no. 5, pp. 1127-1140, DOI: 10.17654/EC017051127.
8. Нгуен В.Х. Применение прогностических регуляторов для управления установками распределенной генерации в системах электроснабжения железных дорог: специальность 05.13.06 "Автоматизация и управление технологическими процессами и производствами (по отраслям)": диссертация на соискание ученой степени кандидата технических наук / Нгуен Ван Хуан, 2021. – 197 с.
9. Булатов Ю.Н. Алгоритмы построения цифрового двойника установки распределенной генерации / Ю.Н. Булатов, А.В. Крюков // Журнал Сибирского федерального университета. Серия: Техника и технологии, 2020. – Т. 13. – № 6. – С. 677-689. – DOI: 10.17516/1999-494X-0256.
10. Bulatov Yu., Kryukov A., Batuhtin A. et al. Digital twin formation method for distributed generation plants of cyber–physical power supply systems. *Mathematics*, 2022, vol. 10, no. 16, p. 2886, DOI: 10.3390/math10162886.
11. Короткова К.Е. Определение влияния параметров системы нечеткого логического вывода на точность построения модели установки распределенной генерации / К.Е. Короткова, А.Д. Ульянов // Системы. Методы. Технологии, 2023. – № 4(60). – С. 89-93. – DOI: 10.18324/2077-5415-2023-4-89-93.
12. Ульянов А.Д. Применение цифровых двойников для решения задач электронегетики, оптимизации и автоматического управления / А.Д. Ульянов, К.Е. Короткова // Труды Братского государственного университета. Серия: Естественные и инженерные науки, 2024. – Т. 1. – С. 22-26.
13. Ульянов А.Д. Понятие «Цифровой двойник» в промышленности / А.Д. Ульянов, К.Е. Короткова // Труды Братского государственного университета. Серия: Естественные и инженерные науки, 2024. – Т. 1. – С. 71-73.
14. Булатов Ю.Н. Распределенная генерация и энергетические роутеры в системах электроснабжения железных дорог / Ю.Н. Булатов, А.В. Крюков, Г.О. Арсентьев. – Москва-Берлин: ООО "Директмедиа Пабблишинг", 2020. – 172 с.
15. Булатов Ю.Н. Оперативное определение запасов статической устойчивости в системах электроснабжения с установками распределенной генерации / Ю.Н. Булатов, А.В. Крюков, К.В. Суслов, А.В. Черепанов // Вестник Иркутского государственного технического университета, 2021. – Т. 25, № 1(156). – С. 31-43. – DOI: 10.21285/1814-3520-2021-1-31-43.
16. Штовба С.Д. Проектирование нечетких систем средствами MATLAB. – М.: Горячая линия – Телеком, 2007. – 288 с.

**Короткова Ксения Евгеньевна.** Соискатель, Институт информационных технологий и анализа данных им. Е.И. Попова ФГБОУ ВО Иркутский национальный исследовательский технический университет. AuthorID: 1123771, SPIN: 1893-6701, kseniakorotkovs@yandex.ru. 664074 Иркутск, ул. Лермонтова, 83.

**Говорков Алексей Сергеевич.** К.т.н., директор, Институт информационных технологий и анализа данных им. Е.И. Попова ФГБОУ ВО Иркутский национальный исследовательский технический университет. AuthorID: 667979, SPIN: 4791-7021, ORCID: 0000-0001-9684-8572, govorkov\_as@ex.istu.edu. 664074 Иркутск, ул. Лермонтова, 83.

UDC 681.323

DOI:10.25729/ESI.2026.42.2.010

## Methodology for building digital twins of distributed generation systems using fuzzy models

**Kseniya E. Korotkova, Aleksey S. Govorkov**

National Research Irkutsk State Technical University, Russia, Irkutsk, kseniakorotkovs@yandex.ru

**Abstract.** The article discusses the main components of digital twins and their interconnections, the specific features of distributed generation units, and the challenges that arise during their use. Digital twin technology is currently widely used in industrial production. Digital twins act as virtual analogues of physical objects, groups of objects, or processes. They are complex software solutions based on large volumes of data and the synthesis of artificial intelligence, machine learning, and specialized software, enabling the creation of dynamic digital models capable of live interaction and adaptation. The article presents a methodology for constructing digital twins of distributed generation units, the use of which helps optimize the design, operation, and monitoring of electric power systems. The methodology is presented using a turbogenerator unit as an example and includes the following stages: collecting data on the physical object, modeling the turbogenerator unit, and comparing experimental data and the response of a fuzzy model. The scientific novelty of the study lies in the development of a hybrid approach combining neural networks, a fuzzy inference system, and a genetic algorithm. The study identified the minimum root-mean-square deviation (RMS) of the model's response to experimental data, determined the optimal number of rules in a fuzzy system (144 rules), and established the relationship between model accuracy and computational costs. The practical significance of the results lies in the potential application of the developed method to optimize the operation of distributed generation units, improve power supply reliability, and enhance the management efficiency of electric power systems. The proposed approach enables the creation of accurate digital models capable of adapting to changing operating conditions. The research findings can be used in the development of new energy systems, the modernization of existing facilities, and the implementation of Smart Grid technologies. The proposed approach opens new prospects for the development of energy-efficient and reliable power supply systems.

**Keywords:** digital twins, distributed generation installations, Smart Grids

### References

1. Grieves M.W. Digital twin: manufacturing excellence through virtual factory replication. LLC, 2014, 7 p.
2. Mukhlina E.S., Logacheva A.G. Budushcheye tsifrovyykh dvoynikov v energetike [The future of digital twins in energy]. Dispetcherizatsiya i upravleniye v elektroenergetike: materialy XV Vserossiyskoy otkrytoy molodezhnoy nauchno-prakticheskoy konferentsii [Dispatch and Control in Electric Power Industry: Proceedings of the XV All-Russian Open Youth Scientific and Practical Conference]. Kazan, KSEU Publ., 2020, pp. 354-356.
3. Jia L., Li Z., Hu Z. Applications of the internet of things in renewable power systems: a survey. *Energies*, 2024, vol. 17, no. 16, p. 4160, DOI: 10.3390/en17164160.
4. Boháčik A., Fujdiak R. The problem of integrating digital twins into electro-energetic control systems. *Smart Cities*, 2024, vol. 7, no. 5, pp. 2702-2740, DOI: 10.3390/smartcities7050105.
5. Bulatov Yu., Kryukov A., Batuhtin A. et al. Digital twin formation method for distributed generation plants of cyber-physical power supply systems. *Mathematics*, 2022, vol. 10, no. 16, p. 2886, DOI: 10.3390/math10162886.

6. Bulatov Yu.N., Korotkova K.E. Application of digital twin technologies in the energy sector. Proceedings of the Bratsk State University. Series: Natural and Engineering Sciences, 2012, vol. 1, pp. 103-112.
7. Kryukov A.V., Kargapol'tsev S.K., Bulatov Yu.N. et al. Intelligent control of the regulators adjustment of the distributed generation installation. Far East Journal of Electronics and Communications, 2017, vol. 17, no. 5, pp. 1127-1140, DOI: 10.17654/EC017051127.
8. Nguyen V.H. Primeneniye prognosticheskikh regulyatorov dlya upravleniya ustanovkami raspredelennoy generatsii v sistemakh elektrosnabzheniya zheleznikh dorog [Application of predictive controllers for controlling distributed generation installations in railway power supply systems]. PhD dissertation. 2021, 197 p.
9. Bulatov Yu.N., Kryukov A.V. Algoritmy postroyeniya tsifrovogo dvoynika ustanovki raspredelennoy generatsii [Algorithms for constructing a digital twin of a distributed generation installation]. Zhurnal Sibirskogo federal'nogo universiteta. Seriya: Tekhnika i tekhnologii [Journal of Siberian federal university. Series: Engineering and technologies], 2020, vol. 13, no. 6, pp. 677-689, DOI: 10.17516/1999-494X-0256.
10. Bulatov Yu., Kryukov A., Batuhtin A. et al. Digital twin formation method for distributed generation plants of cyber-physical power supply systems. Mathematics, 2022, vol. 10, no. 16, p. 2886, DOI: 10.3390/math10162886.
11. Korotkova K.E., Ulyanov A.D. Opredeleniye vliyaniya parametrov sistemy nechetkogo logicheskogo vyvoda na tochnost' postroyeniya modeli ustanovki raspredelennoy generatsii [Determining the influence of fuzzy inference system parameters on the accuracy of building a distributed generation installation model]. Sistemy. Metody. Tekhnologii [Systems. Methods. Technologies], 2023, no. 4(60), pp. 89-93, DOI: 10.18324/2077-5415-2023-4-89-93.
12. Ulyanov A.D., Korotkova K.E. Primeneniye tsifrovyykh dvoynikov dlya resheniya zadach elektroenergetiki, optimizatsii i avtomaticheskogo upravleniya [Application of digital twins for solving problems of electric power industry, optimization and automatic control]. Trudy Bratskogo gosudarstvennogo universiteta. Seriya: Estestvennyye i inzhenernyye nauki [Proceedings of Bratsk state university. Series: Natural and engineering sciences], 2024, vol. 1, pp. 22-26.
13. Ulyanov A.D., Korotkova K.E. Ponyatiye "Tsifrovoy dvoynik" v promyshlennosti [The concept of "digital twin" in industry]. Trudy Bratskogo gosudarstvennogo universiteta. Seriya: Estestvennyye i inzhenernyye nauki [Proceedings of Bratsk State University. Series: Natural and Engineering Sciences], 2024, vol. 1, pp. 71-73.
14. Bulatov Yu.N., Kryukov A.V., Arsentiev G.O. Raspredelennaya generatsiya i energeticheskiye routing v sistemakh elektrosnabzheniya zheleznikh dorog [Distributed generation and energy routers in railway power supply systems]. Moscow; Berlin, Directmedia Publishing, 2020, 172 p. ISBN: 978-5-4499-0083-8.
15. Bulatov Yu.N., Kryukov A.V., Suslov K.V., Cherepanov A.V. Operativnoye opredeleniye zapasov staticheskoy ustoychivosti v sistemakh elektrosnabzheniya s ustanovkami raspredelennoy generatsii [Operational determination of static stability margins in power supply systems with distributed generation installations]. Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta [Bulletin of Irkutsk state technical university], 2021, vol. 25, no. 1(156), pp. 31-43, DOI: 10.21285/1814-3520-2021-1-31-43.
16. Shtovba S.D. Proyektirovaniye nechetkikh sistem sredstvami MATLAB [Design of fuzzy systems using MATLAB]. Moscow, Goryachaya liniya – Telekom Publ., 2007, 288 p.

**Korotkova Kseniya Evgen'evna.** *Scientific degree applicant of the Institute of Information Technologies and Data Analysis named after. E.I. Popova, Irkutsk National Research Technical University. AuthorID: 1123771, SPIN: 1893-6701, kseniakorotkovs@yandex.ru. 664074 Irkutsk, Lermontov street 83.*

**Govorkov Aleksey Sergeevich.** *Candidate of Technical Sciences, Associate Professor, Director of the Institute of Information Technologies and Data Analysis named after. E.I. Popova, Federal State Budgetary Educational Institution of Higher Education Irkutsk National Research Technical University. AuthorID: 667979, SPIN: 4791-7021, ORCID: 0000-0001-9684-8572, govorkov\_as@ex.istu.edu. 664074, Irkutsk, Lermontov street 83.*

*Статья поступила в редакцию 21.05.2025; одобрена после рецензирования 04.10.2025; принята к публикации 10.02.2026.*

*The article was submitted 05/21/2025; approved after reviewing 10/04/2025; accepted for publication 02/10/2026.*

УДК 621.47 621.314

DOI:10.25729/ESI.2026.42.2.011

## Исследование потерь мощности в полупроводниковых преобразователях фотоэлектрических установок

Довудов Сарфароз Умедович<sup>1</sup>, Дунаев Михаил Павлович<sup>2</sup>, Султонзода Шерхон Муртазо<sup>1</sup>, Хакимова Манижа Абдувосеевна<sup>3</sup>

<sup>1</sup>Таджикский технический университет имени академика М.С. Осими, Таджикистан, Душанбе, *sarfarozdovudov@gmail.com*

<sup>2</sup>Иркутский национальный исследовательский технический университет, Россия, Иркутск

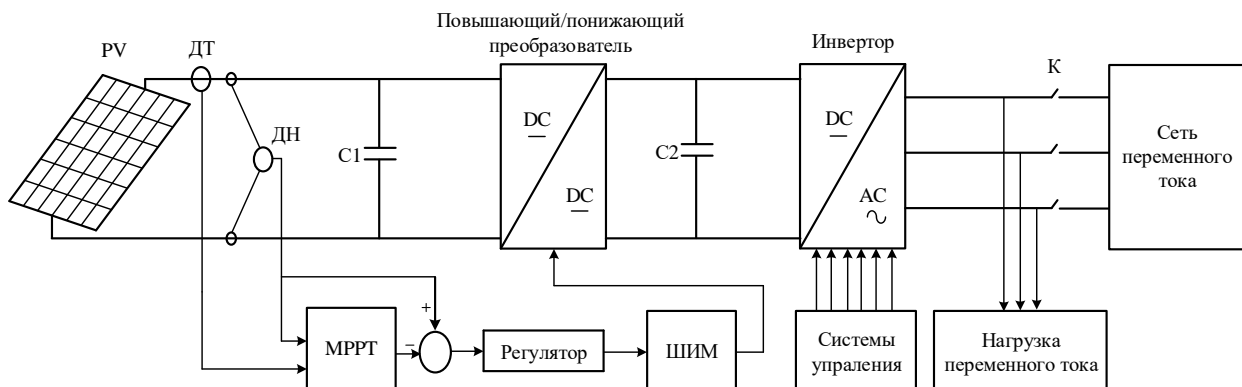
<sup>3</sup>Международный университет туризма и предпринимательства Таджикистана, Таджикистан, Душанбе

**Аннотация.** В статье выполнен анализ энергетической эффективности полупроводниковых преобразователей постоянного тока (DC/DC – converter), которые используются в фотоэлектрических установках. Исследование потерь мощности в ключах повышающего преобразователя (boost converter) с широтно-импульсной модуляцией (ШИМ) проводилось с помощью имитационной компьютерной модели, разработанной в среде MATLAB с использованием блоков из Simscare. Представлены результаты имитационного компьютерного моделирования графиков зависимости выходных тока и напряжения при ступенчатом изменении солнечного излучения. Установлено, что при увеличении солнечного излучения ток и напряжение возрастают, что указывает на прямую зависимость генерируемого тока и напряжения от уровня освещённости. Разработанная модель позволяет определить статические и динамические потери мощности в силовых полупроводниковых ключах в зависимости от частоты коммутации. Анализ исследований показал, что полупроводниковый преобразователь постоянного тока в постоянный (DC/DC) с ШИМ-управлением имеет значительные потери при включении и выключении полупроводниковых ключей, что приводит к снижению КПД преобразователя. Для уменьшения динамических потерь и увеличения КПД полупроводникового преобразователя необходимо исследовать новый метод управления, который основывается на применении частотно-импульсной модуляции (ЧИМ).

**Ключевые слова:** полупроводниковый преобразователь, фотоэлектрическая установка, широтно-импульсная модуляция, энергетическая эффективность, потери мощности

**Цитирование:** Довудов С.У. Исследование потерь мощности в полупроводниковых преобразователях фотоэлектрических установок / С.У. Довудов, М.П. Дунаев, Ш.М. Султонзода, М.А. Хакимова // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 143-152. – DOI:10.25729/ESI.2026.42.2.011.

**Введение.** Структурная схема фотоэлектрической системы с преобразованием энергии и подключением к нагрузке и сети переменного тока показана на рисунке 1. Основным элементом системы является фотоэлектрическая панель (PV), которая преобразует солнечную энергию в постоянное напряжение [1, 2].



**Рис. 1.** Структурная схема фотоэлектрической системы

Выходное напряжение и ток с фотоэлектрической панели (PV) снимаются через датчики тока (ДТ) и напряжения (ДН) и подаются на вход системы слежения за точкой максимальной

мощности (MPPT). Система MPPT реализует алгоритм отслеживания точки максимальной мощности, который формирует управляющий сигнал для обеспечения оптимального режима работы фотоэлектрической панели.

На регулятор поступает сигнал управления, формирующий управляющий сигнал для блока широтно-импульсной модуляции (ШИМ). ШИМ управляет полупроводниковыми ключами DC/DC-преобразователя, стабилизируя напряжение на выходе и обеспечивая его соответствие требованиям инвертора.

Инвертор играет важную роль при преобразовании постоянного напряжения, полученного от DC/DC-преобразователя в переменное напряжение синусоидальной формы [2]. Переменный ток, полученный на выходе инвертора, подается как на нагрузку переменного тока, так и через коммутирующее устройство (К) в сеть переменного тока. Таким образом, обеспечивается как автономная работа системы, так и параллельная работа с внешней сетью.

В настоящее время в фотоэлектрических установках используются разные виды DC/DC-преобразователей. Важнейшим показателем их работы является энергетическая эффективность, которая определяется следующими показателями:

- диапазон регулирования выходного напряжения должен соответствовать выходному напряжению солнечной панели в точке максимальной мощности (ТТМ) при различных условиях освещенности;
- наличие алгоритма поиска точки максимальной мощности на всем диапазоне регулирования выходного напряжения, что позволяет обеспечить максимальную выходную мощность при любых уровнях освещенности солнечных панелей;
- непрерывность и малые пульсации входного тока, что способствует продлению срока службы солнечных панелей и повышению точности определения ТТМ;
- наличием гальванической изоляции, если предъявляются дополнительные требования по безопасности;
- коэффициент полезного действия (КПД), зависящий от статических и динамических потерь в ключах;
- дополнительные потери, связанными с сопротивлением проводников и питанием цепей управления.

Указанным выше показателям удовлетворяют несколько типов преобразователей без гальванической изоляции, такие, как: понижающий преобразователь (buck converter); повышающий преобразователь (boost converter), повышающе-понижающий преобразователь (buck-boost converter); преобразователь с первичной индуктивностью одностороннего включения (SEPIC – Single-Ended Primary Inductance Converter) и преобразователь Кука (Cuk converter).

Понижающий преобразователь является самым простым с точки зрения схемотехники и системы управления, который обеспечивает регулирование выходного напряжения в диапазоне от нуля до величины входного напряжения [3, 4]. Электрическая схема понижающего преобразователя постоянного тока с фотоэлектрической панелью (PV) показана на рисунке 2. Схема включает: фотоэлектрическую панель (PV), силовой полупроводниковой ключ на транзисторе VT1, диод VD1, катушку индуктивности L1 и конденсаторы фильтра C1 и C2. Резистор Rн представляет собой нагрузку постоянного тока. В качестве полупроводникового ключа наиболее часто используется биполярный транзистор с изолированным затвором (IGBT). Диод VD1 называется обратным диодом. Транзистор VT1 управляется ШИМ-сигналом, который включает и выключает с частотой  $f = 1/T$ .




Рис. 2. Понижающий преобразователь (buck converter)

Повышающий преобразователь, схема которого показана на рисунке 3, используется в тех случаях, когда необходимо получить выходное напряжение, превышающее напряжение источника питания. Важной особенностью повышающего преобразователя является то, что он потребляет от источника питания непрерывный ток (в понижающем преобразователе для этого требуется дополнительный фильтрующий входной конденсатор).




Рис. 3. Повышающий преобразователь (boost converter)

Преимуществами использования ШИМ в полупроводниковых преобразователях постоянного тока является малое количество компонентов, высокая эффективность, относительно простое управление и коммерческая доступность контроллеров и интегральных схем, а также возможность достижения высоких коэффициентов преобразования как для понижающих, так и для повышающих преобразователей.

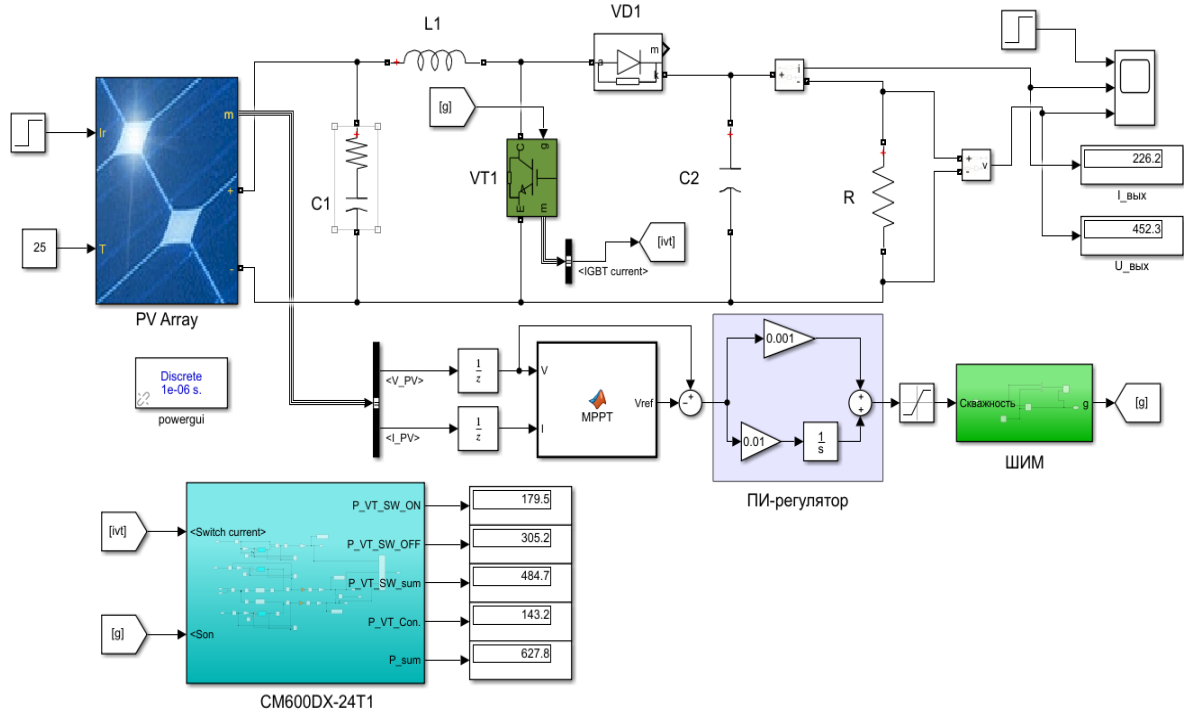
Недостатком преобразователей постоянного тока в постоянный (DC/DC) с ШИМ является значительные потери при включении и выключении в полупроводниковых устройствах, снижающие КПД преобразователя. Поэтому исследование влияния ШИМ на энергетическую эффективность работы преобразователя в составе солнечных электроустановок является актуальной задачей и требует научного подхода.

**Моделирование полупроводникового преобразователя фотоэлектрической установки.** Программная среда MATLAB является одной из наиболее известных программ для исследования силовых преобразователей, которая позволяет моделировать практически любую схему преобразователя, входящего в солнечную электростанцию, с любым алгоритмом модуляции. Для анализа потерь мощности в ключах полупроводниковых преобразователей фотоэлектрической установки в программе MATLAB с использованием блоков из библиотеки Simscare разработана имитационная компьютерная модель фотоэлектрической установки с ШИМ-регулированием.

Имитационная компьютерная модель, показанная на рисунке 4, содержит следующие блоки:

- фотоэлектрический модуль (PV array), преобразующий солнечное излучение в электрическую энергию. Электрические параметры PV модуля зависят от освещённости и температуры, которые задаются на его входах с помощью блоков Constant;

- блок МРРТ (Maximum Power Point Tracking), реализованный методом возмущения и наблюдения (Perturb and Observe), который измеряет ток и напряжение с выхода PV и вычисляет соответствующую точку максимальной мощности;
- блок ПИ-регулятора, обеспечивающий регулирование ключа IGBT-транзистора с нужной скважностью. Ошибка между текущим и опорным напряжением подается на ПИ-регулятор, выход которого управляет ШИМ;
- блок регулирования ШИМ, который формирует управляющий сигнал для IGBT-транзистора на основе выходного сигнала регулятора. Это позволяет эффективно регулировать передачу мощности от PV к нагрузке;
- блок расчета потерь мощности в преобразователе;
- комплект измерительных приборов, который измеряет напряжение и ток нагрузки.



**Рис. 4.** Имитационная компьютерная модель фотоэлектрической установки с ШИМ-регулированием

**Широтно-импульсная модуляция.** На рисунке 5 приведена модель блока формирования ШИМ и диаграммы ее работы. В нашем случае блок формирования ШИМ реализован с использованием генератора треугольного напряжения (ГТН) на интеграторе и компаратора, сравнивающего выходное напряжение ГТН  $U_{ГТН}$  с управляющим напряжением  $U_u$ , пропорциональным заданной величине управляющего сигнала [6].

При  $U_{ГТН} < U_u$  на выходе компаратора в течение времени  $t_v$  формируется напряжение высокого уровня (рис. 5б), поддерживающее ключевой элемент импульсного преобразователя в открытом состоянии. В оставшуюся часть периода  $T$  пилообразного напряжения  $t_{п} = T - t_v$  на выходе компаратора поддерживается напряжение низкого уровня, при котором ключевой элемент преобразователя находится в закрытом состоянии. Изменение управляющего напряжения осуществляет изменение скважности импульсного цикла  $\gamma = \frac{t_v}{T}$ , следовательно, происходит широтно-импульсное регулирование напряжения на нагрузке при постоянной частоте  $f = 1/T$ .

В этой модели для расчета потерь мощности в модулях IGBT-транзисторов выбран IGBT-транзистор типа CM600DX-24T1 фирмы MITSUBISHI с номинальным током 600 А, максимальным напряжением между коллектором и эмиттером  $U_{CE} = 1200$  В.

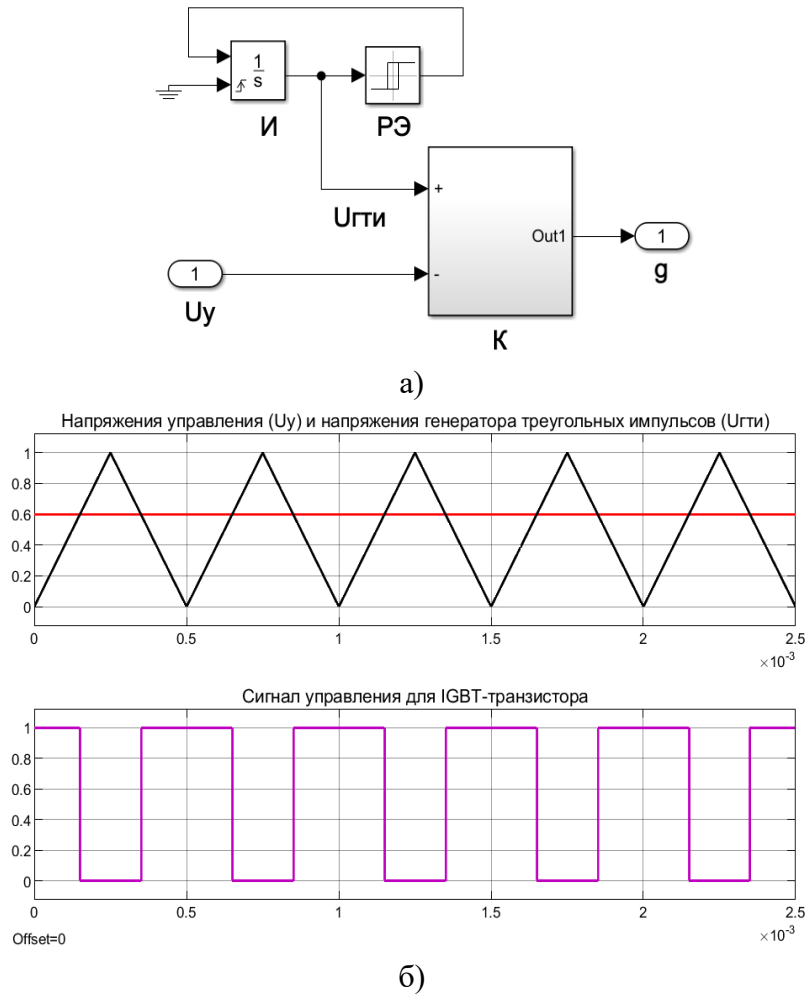


Рис. 5. Модель системы управления ШИМ (а) и диаграммы ее работы (б)

Определение статических и динамических потерь мощности в силовых ключах выполнено путем разработанной имитационной модели, которая подробно описана в работах [5-10]. Имитационные модели блоков расчета статических и динамических потерь мощности в IGBT-транзисторе типа CM600DX-24T1 приведены на рисунке 6.

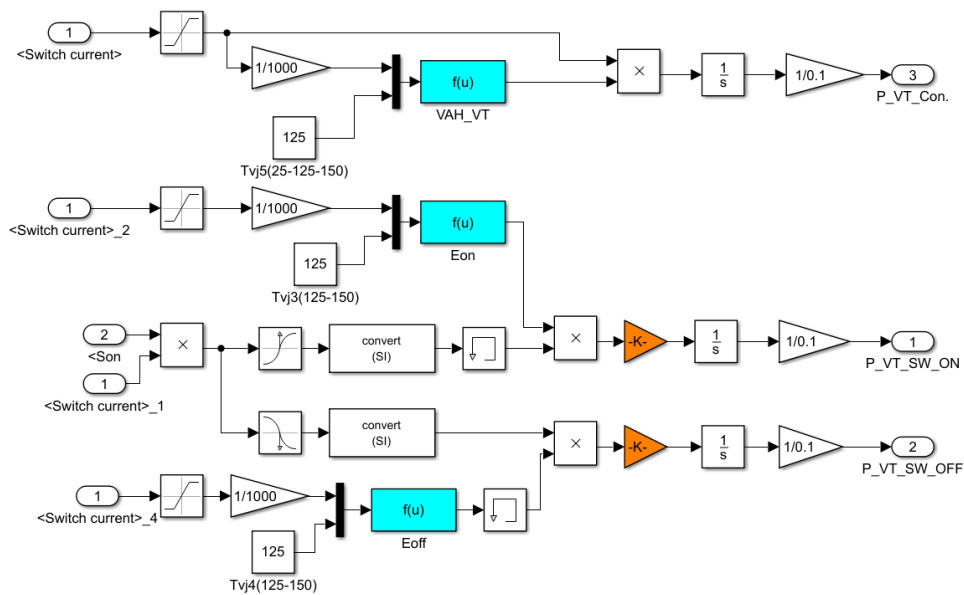



Рис. 6. Имитационные модели расчета статических и динамических потерь мощности в IGBT-транзисторе

Результаты моделирования зависимостей выходного тока и напряжения при ступенчатом изменении солнечной инсоляции при ШИМ-регулировании преобразователя приведены на рисунке 7 [8]. Первый график показывает изменение плотности солнечного излучения: на интервале до 0.1 секунды она остается на уровне 500 Вт/м<sup>2</sup>, после чего резко увеличивается до 1000 Вт/м<sup>2</sup>. Второй график показывает изменение выходного тока при изменении уровня инсоляции. При увеличении солнечного излучения ток возрастает с уровня 150 А до уровня 220 А, что указывает на прямую зависимость генерируемого тока от уровня освещенности. На третьем графике представлена зависимость выходного напряжения. Аналогично току, напряжение также возрастает с ростом инсоляции с уровня 300 В до уровня, превышающего 400 В. Пульсация на графиках тока и напряжения свидетельствует о наличии высокочастотных колебаний, характерных для преобразовательных схем с ШИМ.




**Рис. 7.** Результаты моделирования зависимостей выходного тока и напряжения при ступенчатом изменении солнечной инсоляции

На рисунке 8 показаны графики статических и динамических потерь мощности в IGBT-транзисторе схемы преобразователя постоянного тока с широтно-импульсной модуляцией. Как видно, с увеличением частоты коммутации увеличиваются динамические потери мощности в ключе, а статические потери мощности не зависят от частоты коммутации. Увеличение динамических потерь приводит к уменьшению КПД преобразователя.

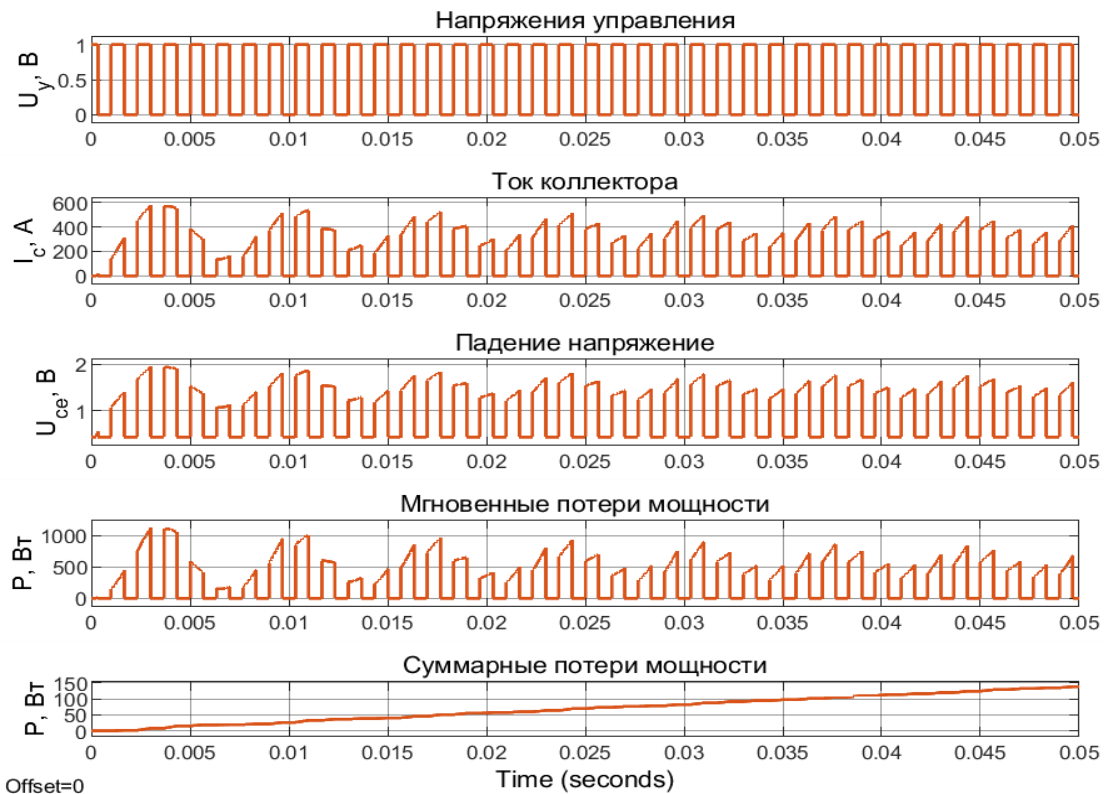
Результаты моделирования статических и динамических потерь мощности в IGBT-транзисторе приведены на рисунках 9 и 10. Входными сигналами для расчета потерь мощности в среде Matlab являются сигналы управления IGBT-транзистором и ток коллектора IGBT-транзистора. Результаты расчетов статических и динамических потерь мощности в IGBT-транзисторе преобразователя с ШИМ-регулированием приведены в таблице 1.

**Таблица 1.** Энергетические показатели полупроводникового преобразователя фотоэлектрических установок при различных частотах коммутации


f, кГц	I <sub>ВЫХ</sub> , А	U <sub>ВЫХ</sub> , В	P <sub>vt_sw_on</sub> , Вт	P <sub>vt_sw_off</sub> , Вт	P <sub>vt_sw_sum</sub> , Вт	P <sub>vt_con</sub> , Вт	P <sub>sum</sub> , Вт
1	216,5	432,9	16,12	32,86	48,98	145,1	194,1
2	221,3	442,6	34,88	64,01	98,89	145,1	244
4	222,8	445,6	71,14	124,7	195,8	141,5	337,3
6	216,8	433,6	106,9	184,3	291,1	142,8	433,9
8	220,6	441,3	143,3	245	388,3	143,1	531,4
10	226,2	452,3	179,5	305,2	484,7	143,2	627,8



**Рис. 8.** Графики потерь мощности в силовых транзисторах в зависимости от частоты коммутации



**Рис. 9.** Результаты моделирования статических потерь мощности в IGBT-транзисторе



**Рис. 10.** Результаты моделирования динамических потерь мощности в IGBT-транзисторе

**Заключение.** Исследование показало, что коэффициент полезного действия (КПД) полупроводниковых преобразователей фотоэлектрических установок зависит от статических и динамических потерь мощности, которые возникают в ключах. Динамические потери (таблица 1) в полупроводниковых ключах преобразователей прямо пропорциональны частоте коммутации: чем выше частота коммутации, тем больше динамические потери. Для уменьшения динамических потерь и увеличения КПД полупроводникового преобразователя фотоэлектрических установок необходимо исследовать новый метод управления, который основывается на применении частотно-импульсной модуляции (ЧИМ). Дальнейшее исследование будет направлено на разработку структурных, математических и имитационных моделей, а также реализацию ЧИМ в полупроводниковых преобразователях для фотоэлектрических установок.

#### Список источников

1. Fidje A., Martinsen T. Effects of climate change on the utilization of solar cells in the Nordic region. European Conference on Impacts of Climate on Renewable Energy Sources, 2006, pp. 1-4.
2. Kocalmis Bilhan A., Caliskan A., Unal S. Simulation of photovoltaic panels by using Matlab/simulink. ECAI International Conference, 2016, pp. 1-5, DOI:10.1109/ECAI.2016.7861124.
3. Bharathy Priya D., Sumathi A. Modeling and simulation of solar PV energy conversion systems. International Journal of Engineering and Advanced Technology, 2019, vol. 8, no. 6S3, pp. 1026-1031, DOI:10.35940/ijeat.F1216.0986S319.
4. Kumar N., Hussain I., Singh B., Panigrahi B.K. Normal harmonic search algorithm-based MPPT for solar PV system and integrated with grid using reduced sensor approach and PNKLMS algorithm. IEEE Transactions on Industry Applications, 2018, vol. 54, no. 6, pp. 6343-6352, DOI: 10.1109/TIA.2018.2853744.
5. Suryoatmojo H. et al. Design of MPPT based fuzzy logic for solar-powered unmanned aerial vehicle application. In: ICEAST 2018 - 4th International Conference on Engineering, Applied Sciences and Technology: Exploring Innovative Solutions for Smart Society, 2018, DOI:10.1109/ICEAST.2018.8434430.
6. Дунаев М.П. Сравнение энергоэффективности схем автономных инверторов напряжения с синусоидальной широтно-импульсной и частотно-импульсной модуляцией / М.П. Дунаев, С.У. Довудов // Электротехнические системы и комплексы, 2021. – № 4(53). – С. 50-55. – DOI:10.18503/2311-8318-2021-4(53)-50-55.
7. Свидетельство о государственной регистрации программы для ЭВМ № 2021665863 Российская Федерация. Программа для расчета потерь в преобразователе частоты : № 2021665177: заявл. 01.10.2021:

опубл. 04.10.2021 / А. М. Дунаев, С. У. Довудов; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования "Иркутский национальный исследовательский технический университет".

8. Dovudov S., Dunaev M., Zhiravetska A. et al. Improving energy indicators of pulse converters. Indonesian Journal of Electrical Engineering and Computer Science, 2025, vol. 37, no. 3, p. 1442, DOI: 10.11591/ijeecs.v37.i3.pp1442-1451.
9. Al-Rawashdeh A.Y., Dunayev M.P., Alzyoud Kh.Y. et al. Calculation of power losses in a frequency inverter. International Journal of Power Electronics and Drive Systems, 2024, vol. 15, no. 3, p. 1331, DOI: 10.11591/ijpeds.v15.i3.pp1331-1338.
10. Довудов С.У. Анализ эффективности автономных инверторов напряжения в фотоэлектрических установках / С.У. Довудов // Политехнический вестник. Серия: Инженерные исследования, 2025. – № 2(70). – С. 21-32.

**Довудов Сарфароз Умедович.** Ассистент, Таджикский технический университет имени академика М. С. Осими. AuthorID: 909554, SPIN: 3114-9592, ORCID:0000-0001-5600-4615, sarfarozdovudov@gmail.com, 734042, г. Душанбе, проспект академиков Раджабовых 10, Таджикистан.

**Дунаев Михаил Павлович.** Доктор технических наук, профессор, профессор Иркутского национального исследовательского технического университета. AuthorID: 315898, SPIN: 1459-8239, ORCID:0000-0002-1523-5553, mdunaev10@mail.ru, 664074, Иркутская обл., Иркутск, ул. Лермонтова, 83, Россия.

**Султонзода Шерхон Муртазо.** Кандидат технических наук, доцент, заведующий кафедрой электрические станции, Таджикский технический университет имени академика М.С. Осими. AuthorID: 909760, SPIN: 6856-3537, ORCID: 0000-0003-2322-5272, sultonzoa.sh@mail.ru, 734042, г. Душанбе, проспект академиков Раджабовых 10, Таджикистан.

**Хакимова Манижа Абдусеитовна.** Ассистент, Международный университет туризма и предпринимательства Таджикистана. SPIN: 7445-7568, ORCID: 0009-0008-1909-5368, manizhahakimova@bk.ru, 734042, г. Душанбе, ул. Борбад 48/5, Таджикистан.

UDC 621.47 621.314

DOI:10.25729/ESI.2026.42.2.011

## Analysis of power losses in semiconductor converters for photovoltaic installations

Sarfarozi U. Dovudov<sup>1</sup>, Mikhail P. Dunaev<sup>2</sup>, Sherkhon M. Sultonzada<sup>1</sup>, Manija A. Hakimova<sup>3</sup>

<sup>1</sup>Tajik Technical University named after academic M.S. Osimi, Tajikistan, Dushanbe, sarfarozdovudov@gmail.com

<sup>2</sup>National Research Irkutsk State Technical University, Russia, Irkutsk

<sup>3</sup>International University of Tourism and Entrepreneurship, Tajikistan, Dushanbe

**Abstract.** This article presents an analysis of the energy efficiency of semiconductor direct current converters (DC/DC converters) used in photovoltaic installations. The study of power losses in the switches of a boost converter with pulse-width modulation (PWM) was carried out using a simulation computer model developed in the MATLAB environment with blocks from Simscape. The results of the simulation modeling of the graphs showing the dependence of output current and voltage on step changes in solar irradiance are presented. It has been established that with an increase in solar irradiance, the current and voltage increase, indicating a direct dependence of the generated current and voltage on the level of illumination. The developed model allows the determination of static and dynamic power losses in power semiconductor switches depending on the switching frequency. The analysis of the study showed that the DC-to-DC semiconductor converter with PWM control experiences significant losses during the switching on and off of semiconductor switches, which leads to a reduction in the efficiency of the converter. To reduce dynamic losses and increase the efficiency of the semiconductor converter, it is necessary to investigate a new control method based on the application of frequency-pulse modulation (FPM).

**Keywords:** semiconductor converter, photovoltaic system, pulse-width modulation, energy efficiency, power losses

## References

1. Fidje A., Martinsen T. Effects of climate change on the utilization of solar cells in the Nordic region. European Conference on Impacts of Climate on Renewable Energy Sources, 2006, pp. 1-4.
2. Kocalmis Bilhan A., Caliskan A., Unal S. Simulation of photovoltaic panels by using Matlab/simulink. ECAI International Conference, 2016, pp. 1-5, DOI:10.1109/ECAI.2016.7861124.
3. Bharathy Priya D., Sumathi A. Modeling and simulation of solar PV energy conversion systems. International Journal of Engineering and Advanced Technology, 2019, vol. 8, no. 6S3, pp. 1026-1031, DOI:10.35940/ijeat.F1216.0986S319.
4. Kumar N., Hussain I., Singh B., Panigrahi B.K. Normal harmonic search algorithm-based MPPT for solar PV system and integrated with grid using reduced sensor approach and PNKLM algorithm. IEEE Transactions on Industry Applications, 2018, vol. 54, no. 6, pp. 6343-6352, DOI: 10.1109/TIA.2018.2853744.
5. Suryoatmojo H. et al. Design of MPPT based fuzzy logic for solar-powered unmanned aerial vehicle application. In: ICEAST 2018 - 4th International Conference on Engineering, Applied Sciences and Technology: Exploring Innovative Solutions for Smart Society, 2018, DOI:10.1109/ICEAST.2018.8434430.
6. Dunaev M.P., Dovudov S.U. Sravneniye energoeffektivnosti skhem avtonomnykh inverterov napryazheniya s sinusoidal'noy shirotno-impul'snoy i chastotno-impul'snoy modulyatsiyey [Comparison of energy efficiency of standalone voltage inverter circuits with sinusoidal pulse-width modulation and frequency-pulse modulation]. Elektrotekhnicheskiye sistemy i komplekсы [Electrotechnical Systems and Complexes], 2021, no. 4(53), pp. 50-55, 10.18503/2311-8318-2021-4(53)-50-55.
7. Dunaev A.M., Dovudov S.U. Programma dlya rascheta poter' v preobrazovatele chastoty [Program for calculating losses in a frequency converter]. State registration certificate of computer program No. 2021665863 Russian Federation: No. 2021665177: appl. 10.01.2021: publ. 10.04.2021; applicant Irkutsk National Research Technical University.
8. Dovudov S., Dunaev M., Zhiravetska A. et al. Improving energy indicators of pulse converters. Indonesian Journal of Electrical Engineering and Computer Science, 2025, vol. 37, no. 3, p. 1442, DOI: 10.11591/ijeecs.v37.i3.pp1442-1451.
9. Al-Rawashdeh A.Y., Dunayev M.P., Alzyoud Kh.Y. et al. Calculation of power losses in a frequency inverter. International Journal of Power Electronics and Drive Systems, 2024, vol. 15, no. 3, p. 1331, DOI: 10.11591/ijpeds.v15.i3.pp1331-1338.
10. Dovudov S.U. Analiz effektivnosti avtonomnykh inverterov napryazheniya v fotoelektricheskikh ustanovkakh [Efficiency analysis of standalone voltage inverters in photovoltaic installations]. Politekhicheskiy vestnik. Seriya: Inzhenernyye issledovaniya [Polytechnic Bulletin. Series: Engineering Research], 2025, no. 2(70), pp. 21-32.

**Dovudov Sarfaroz Umedovich.** Assistant, Tajik Technical University named after academic M.S. Osimi. AuthorID: 909554, SPIN: 3114-9592, ORCID: 0000-0001-5600-4615, sarfarozdovudov@gmail.com, 734042, Dushanbe, Academics Rajabov Street 10, Tajikistan.

**Dunaev Mikhail Pavlovich.** Doctor of Technical Sciences, Professor, Professor at Irkutsk National Research Technical University, AuthorID: 315898, SPIN: 1459-8239, ORCID: 0000-0002-1523-5553, mdunaev10@mail.ru, 664074, Irkutsk Region, Irkutsk, Lermontova Street 83, Russia.

**Sultonzoada Sherkhon Murtazo.** Candidate of Technical Sciences, Tajik Technical University named after academic M.S. Osimi, AuthorID: 909760, SPIN: 6856-3537, ORCID: 0000-0003-2322-5272; 734042, Dushanbe, Academics Rajabov Street 10, Tajikistan.

**Hakimova Manija Abduvoseevna.** Assistant, International University of Tourism and Entrepreneurship of Tajikistan, SPIN: 7445-7568, ORCID: 0009-0008-1909-5368, manizhahakimova@bk.ru, 734042, Dushanbe, Borbad Street 48/5, Tajikistan.

Статья поступила в редакцию 09.11.2025; одобрена после рецензирования 10.03.2026; принята к публикации 17.05.2026.

The article was submitted 11/09/2025; approved after reviewing 03/10/2026; accepted for publication 05/17/2026.

## Цифровая экономика и управление

УДК 331.108.2

DOI:10.25729/ESI.2026.42.2.012

### Оптимизация программы мероприятий по кадровой безопасности предприятия методами дискретного программирования

Туктарова Полина Андреевна<sup>1</sup>, Мансурова Юлия Талгатовна<sup>2</sup>, Ялтонская Диана Ильвировна<sup>2</sup>

<sup>1</sup>Иркутский государственный аграрный университет имени А.А. Ежевского, Россия, Иркутская область, Иркутский район, поселок Молодежный, [ptuktarova@gmail.com](mailto:ptuktarova@gmail.com)

<sup>2</sup>Уфимский университет науки и технологий, Россия, Уфа

**Аннотация.** Статья посвящена оптимизации программы мероприятий по кадровой безопасности предприятия на основе методов дискретного (0–1) линейного программирования в условиях ограниченных ресурсов. Актуальность обусловлена тем, что персонал одновременно выступает и ключевым активом, и потенциальным источником внутренних угроз: от непреднамеренных ошибок до осознанных нарушений, приводящих к финансовым потерям. Цель работы – сформировать формализованную модель выбора набора мер кадровой и информационной безопасности, которая при заданных лимитах бюджета и трудозатрат обеспечивает требуемое снижение интегрального риска и максимизирует ожидаемый экономический эффект. В качестве переменных решения используются бинарные показатели включения мероприятий в программу, а критерий оптимальности задаётся, как максимизация чистой годовой экономии (разницы между предотвращённым ущербом и затратами). В модель заложены ограничения по финансированию, доступному фонду человеко-часов, а также опциональное ограничение минимального совокупного эффекта. Исходные данные сформированы для шести альтернативных мероприятий (система предотвращения утечек данных (далее DLP – Data Leakage Prevention), аналитика поведения пользователей и объектов инфраструктуры (далее UEBA-аналитика), усиление многофакторной аутентификации для привилегированных пользователей (далее MFA – Multi-Factor Authentication), e-learning по информационной гигиене, ключевые показатели эффективности (далее KPI – Key Performance Indicators) «раннее оповещение» и расширенный соцпакет) с указанием стоимости, трудоёмкости и ожидаемого сокращения потерь на основе экспертной оценки и статистики инцидентов. Практическая апробация выполнена в среде Python с применением MILP-подхода (ветви-и-границы) (MILP – Mixed-Integer Linear Programming – смешанное целочисленное линейное программирование) и демонстрирует получение оптимального набора мероприятий. Полученное решение обеспечивает укладывание в ресурсные лимиты и достижение целевого эффекта, при этом исключая меры с наихудшим соотношением затрат и ожидаемой пользы. Научно-практическая значимость работы состоит в переводе качественных управленческих рассуждений о кадровой безопасности в воспроизводимую оптимизационную постановку, пригодную для пересчёта при изменении цен, трудовых ресурсов и требований регуляторов.

**Ключевые слова:** кадровая безопасность, инсайдерские угрозы, дискретное программирование, 0–1 оптимизация, UEBA (User and Entity Behavior Analytics – аналитика поведения пользователей и объектов инфраструктуры), DLP (Data Leakage Prevention – система предотвращения утечек данных), MFA (Multi-Factor Authentication – многофакторная аутентификация)

**Цитирование:** Туктарова П.А. Оптимизация программы мероприятий по кадровой безопасности предприятия методами дискретного программирования / П.А. Туктарова, Ю.Т. Мансурова, Д.И. Ялтонская // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 153-160. – DOI:10.25729/ESI.2026.42.2.012.

**Введение.** В современной исследовательской практике оценка кадровой безопасности предприятия опирается на совокупность математических моделей, позволяющих формализовать персонал-ориентированные уязвимости и связать их с наблюдаемыми организационными эффектами. В частности, применяются: 1) модели, описывающие зависимость кадровых уязвимостей от личностных характеристик работников, где отдельные компетенции трактуются, как частные показатели уязвимости, а их относительная значимость задаётся весовыми коэффициентами, определяемыми руководством; 2) модели, учитывающие одновременно личностные и внутриорганизационные детерминанты кадровой безопасности,

в том числе на основе аппарата теории нечётких множеств, что позволяет интегрировать количественные и качественные факторы в единую оценочную процедуру; 3) модели оценки благонадёжности работника, агрегирующие параметры образования, стажа и уровня сформированности компетенций, как основания для управленческих решений в контуре кадровой безопасности. Кадровая безопасность – это процесс предотвращения негативных воздействий на экономическую безопасность организации за счёт снижения рисков и угроз, связанных с персоналом, его интеллектуальным потенциалом и трудовыми отношениями. По определению Н.В. Кузнецовой, кадровая безопасность представляет собой «процесс предотвращения, предупреждения и устранения рисков и угроз со стороны персонала с целью обеспечения стабильного функционирования и развития предприятия» [1].

Для построения прикладных моделей диагностики кадровой безопасности используются индикаторные и экономико-статистические подходы. Индикаторный подход основывается на сопоставлении фактических значений показателей с пороговыми (нормативными) уровнями, а величина отклонения от порога интерпретируется, как мера выраженности угроз. Корреляционно-регрессионный анализ применяется для выявления статистически значимых связей между числом кадрово-обусловленных инцидентов и факторами (например, значениями личностных характеристик персонала), а также для последующего прогнозирования. Методы нечётких множеств, в свою очередь, позволяют повысить определённость при оценивании вклада отдельных компонентов в интегральный показатель кадровой безопасности за счёт работы с лингвистическими переменными и экспертными шкалами.

В логике эмпирической параметризации факторов и инцидентов целесообразно выделить корреляционно-регрессионный анализ, как основной инструмент количественной идентификации влияний (при необходимости – с последующим использованием результатов, как входных параметров для оптимизационных постановок).

В обзорных работах по диагностике кадровой безопасности упоминаются подходы, связанные с оценкой надёжности и параметров персонала, в т.ч. у В.Л. Шапошникова, А.С. Артамкина и К.В. Хорошун [2].

Стабильность и надёжность кадрового состава – ключевой фактор успеха любого предприятия, ведь именно сотрудники одновременно защищают компанию от угроз и могут стать источником их возникновения. Риски, связанные с персоналом, могут быть как сознательными, так и случайными. Небрежность или профессиональные ошибки сотрудников часто приводят к непреднамеренным угрозам и, как следствие, к существенным финансовым потерям для компании.

Учитывая существующие проблемы с обеспечением кадровой безопасности, например, в компании ООО «ЛУКОЙЛ-МЦПБ», целесообразно создать модель, которая при ограничениях бюджета, трудовых ресурсов и нормативов информационной защиты обеспечивает наибольший ожидаемый эффект – снижение интегрального риска внутренних инцидентов. Такая модель позволит оперативно выявлять уязвимости и принимать эффективные меры по их устранению.

Таким образом, реализованные мероприятия, указанные в таблице 1, создадут надёжный цифровой каркас кадровой безопасности, соответствующий целям программы «Бухгалтерия 2025» и служащий долговременной основой для устойчивого развития и конкурентоспособности всего холдинга.

Порядок действий:

1. Определение переменных решения:

$x_i \in \{0,1\}$  – бинарная переменная, равная 1, если мероприятие  $i$  включено в программу. Список мероприятий представлен в таблице 1.

**Таблица 1.** Список мероприятий, создающий надежный цифровой каркас кадровой безопасности

Номер мероприятия	Название мероприятия
$x_1$	Расширение лицензии StaffCop Enterprise на 200 узлов. StaffCop Enterprise — российская DLP-система (Data Leakage Prevention) для мониторинга действий сотрудников, расследования инцидентов и предотвращения утечек данных.
$x_2$	Интенсивный e-learning-курс по информационной гигиене для сотрудников
$x_3$	Повышение уровня многофакторной аутентификации (MFA) для привилегированных пользователей
$x_4$	Система КРП и комплекс «раннего оповещения» о неблагоприятных сотрудниках.

$h_i \geq 0$  – количество человеко-часов персонала, необходимое для реализации мероприятия  $i$ ;

$c_i \geq 0$  – прямые денежные затраты на мероприятие  $i$ ;

$r_i \geq 0$  – ожидаемое годовое сокращение потерь (в рублях) при реализации мероприятия  $i$

– параметр, рассчитанный на основе экспертной оценки UEBA-логов (User and Entity Behavior Analytics – аналитика поведения пользователей и объектов инфраструктуры) и статистики прошлых инцидентов;

UEBA-логи (User and Entity Behavior Analytics – аналитика поведения пользователей и объектов инфраструктуры) представляют собой журналы регистрации действий пользователей и устройств в ИТ-инфраструктуре компании;

$R$  – минимально ожидаемый совокупный эффект, определяемый руководителем безопасности.

### 2. Определение целевой функции:

формулируем задачу, как максимизацию чистой годовой экономии, то есть разницы между предотвращённым ущербом и совокупными издержками [3, 4] по формуле 1:

$$\sum_{i=1}^n (r_i - c_i)x_i \rightarrow \max. \quad (1)$$

Бюджетное ограничение по формуле 2:

$$\sum_{i=1}^n c_i x_i \leq B, \quad (2)$$

где  $B$  – утверждённый годовой бюджет (например, 3 200 000 руб.).

Трудовые ресурсы по формуле 3:

$$\sum_{i=1}^n h_i x_i \leq H, \quad (3)$$

где  $H$  – доступный фонд человеко-часов ИТ-службы и ОКБ за плановый период.

Минимальный целевой эффект (опциональное ограничение качества) по формуле 4:

$$\sum_{i=1}^n r_i x_i \geq R. \quad (4)$$

Таким образом, мы имеем задачу оптимизации по формуле 5:

$$f \rightarrow \max \begin{cases} \sum_{i=1}^n c_i x_i \leq B \\ \sum_{i=1}^n h_i x_i \leq H \\ \sum_{i=1}^n r_i x_i \geq R \end{cases} \quad (5)$$

При линейной форме цели и ограничений, а также дискретной природе переменных  $x_i$  получается задача 0–1 линейного программирования; её можно решать методами ветвей-и-границ, срезовых плоскостей или встроенными MILP-солверами (Mixed-Integer Linear Programming – смешанное целочисленное линейное программирование) [5].

### 3. Интерпретация результата [6,7]:

оптимальное решение возвращает набор мероприятий, который:

- полностью вписывается в финансовый и трудовой лимиты;
- обеспечивает требуемое снижение риска;
- даёт максимальную чистую экономию.

Получившийся вектор  $\vec{x}^*$  позволяет составить дорожную карту внедрения, распределённую по календарным кварталам с учётом технологических зависимостей и кадровой нагрузки [8].

Таким образом, формализованная модель превращает качественные соображения («хорошо бы снизить риск и не выйти за смету») в строгую, проверяемую и оптимизируемую задачу, что обеспечивает прозрачность управленческого выбора и воспроизводимость полученных результатов.

**2. Пути решения описываемой проблемы.** Задача оптимизации была решена для шести альтернативных мероприятий, каждое из которых характеризуется четырьмя атрибутами: прямыми расходами, трудоёмкостью ИТ- и ОКБ-персонала, ожидаемым годовым снижением ущерба от внутренних инцидентов и принадлежностью к определённому классу действий (технологическая защита, организационная профилактика или мотивационный стимул). Годовой бюджет проекта ограничен тремя миллионами двумястами тысячами рублей, а совокупный фонд человеко-часов на внедрение – двумя сотнями [9]. Минимально приемлемый эффект задаётся на уровне 1,6 млн руб. предотвращённых убытков в год – это значение согласовано с дорожной картой уменьшения интегрального риска на 30 %. В таблице 2 представлены данные для мероприятий.

**Таблица 2.** Данные для мероприятий

$x_i$	$c_i$ , руб.	$h_i$ , ч	$r_i$ , руб.
$x_1$	540 000	80	1 200 000
$x_2$	180 000	40	800 000
$x_3$	120 000	60	600 000
$x_4$	150 000	20	250 000

$$B = 3\,200\,000;$$

$$H = 200;$$

$$R = 1\,600\,000.$$

Решение задачи оптимизации:

$$\sum_{i=1}^n (r_i - c_i)x_i \rightarrow \max.$$

$$(1\,200\,000 - 540\,000)x_1 + (800\,000 - 180\,000)x_2 + (600\,000 - 120\,000)x_3 + (250\,000 - 150\,000)x_4 \rightarrow \max.$$

Бюджетное ограничение:

$$540\,000x_1 + 180\,000x_2 + 120\,000x_3 + 150\,000x_4 \leq 3\,200\,000.$$

Ограничение по труду:

$$80x_1 + 40x_2 + 60x_3 + 20x_4 \leq 200.$$

Минимальный целевой эффект:

$$1\,200\,000x_1 + 800\,000x_2 + 600\,000x_3 + 250\,000x_4 \geq 1\,600\,000.$$

Оптимизация выбора мероприятий методом целочисленного линейного программирования (PuLP – Python Linear Programming – библиотека Python для задач линейного программирования). Python-скрипт на библиотеке PuLP решающий задачу 0-1 линейного программирования (листинг 1).

**Листинг 1.** Функция оптимизации задачи линейного программирования

```
import pulp
# Параметры мероприятий
costs = [540_000, 180_000, 120_000, 150_000] # c_i
hours = [80, 40, 60, 20] # h_i
```

```

effects = [1_200_000, 800_000, 600_000, 250_000] # r_i
# Ресурсы и цели
B = 3_200_000 # бюджет
H = 200      # человеко-часов
R = 1_600_000 # минимальный эффект
# Настройка модели
model = pulp.LpProblem("StaffCop_Optimization", pulp.LpMaximize)
x = [pulp.LpVariable(f"x_{i}", cat=pulp.LpBinary) for i in range(len(costs))]
# Целевая функция
model += pulp.lpSum((effects[i] - costs[i]) * x[i] for i in range(len(costs)))
# Ограничения
model += pulp.lpSum(costs[i] * x[i] for i in range(len(costs))) <= B
model += pulp.lpSum(hours[i] * x[i] for i in range(len(costs))) <= H
model += pulp.lpSum(effects[i] * x[i] for i in range(len(costs))) >= R
# UEBA только при DLP
model += x[1] <= x[0]
# Решаем
model.solve(pulp.PULP_CBC_CMD(msg=False))
# Результаты
selected = [i for i in range(len(x)) if pulp.value(x[i]) > 0.5]
print("Выбранные мероприятия (индексы):", selected)
print("Чистая экономия:", pulp.value(model.objective), "руб.")

```

В таблице 3 представлены результаты модели 0-1 линейного программирования, построенной в программе Python [10,11].

**Таблица 3.** Результаты по модели, построенной в Python

Номер мероприятия	Результат
$x_1$	1
$x_2$	1
$x_3$	1
$x_4$	1

**Заключение.** Таким образом, мероприятия 5 и 6 не включены в программу, так как имеют высокий уровень затрат и недостаточно очевидную пользу.

Модель 0-1 линейного программирования, построенная в Python на базе MILP-солвера CBC (CBC – COIN-OR Branch and Cut – Метод ветвей и отсечений (солвер с открытым исходным кодом), максимально увеличивает чистую экономию ( $\sum r_i - \sum c_i$ ) при соблюдении ресурсных и логических ограничений [12, 13]. Оптимальное решение включает четыре мероприятия. Во-первых, расширяется лицензия StaffCop на 200 узлов (540 тыс. руб.; 80 ч IT-инженеров) – это закрывает основной периметр финансового контура. Во-вторых, подключается модуль UEBA- аналитики для глубокой корреляции событий (180 тыс. руб.; 40 ч) с обязательной связкой «только при наличии базовой DLP», что соблюдено автоматически. Третьим элементом становится интенсивная программа e-learning для ста сотрудников (120 тыс. руб.; 60 ч кураторских трудозатрат), позволяющая воспитывать культуру безопасного обращения с данными [14,15]. Наконец, вводится KPI-фонд мотивации за соблюдение регламентов (150 тыс. руб.; 20 ч HR-координации).

Совокупные расходы составляют 990 тыс. руб., трудоёмкость точно соответствует лимиту в 200 ч, а ожидаемое сокращение годовых потерь оценивается в 2,85 млн руб. Таким образом, проект обещает чистую экономию 1,86 млн руб. уже в первый год эксплуатации, превышая операционные издержки почти вдвое и формируя положительный денежный поток менее чем за девять месяцев.

На практике реализация распределяется так: IT-департамент поднимает сервер и разворачивает агентов, ОКБ настраивает политики контроля и пороги UEBA, HR-куратор организует дистанционный курс и фиксирует результаты тестов, а финансовый отдел ежемесячно сверяет фактический эффект (сокращение DSO ( Days Sales Outstanding – период

оборота дебиторской задолженности (финансовый KPI), уменьшение количества алертов критичного уровня, экономия времени аналитиков) с прогнозом модели. Если через квартал отклонение превышает  $\pm 10\%$ , параметры  $r_i$  актуализируются, и оптимизация пересчитывается – модель остаётся «живой» и реагирует на изменения цен, трудовых ресурсов и нормативных требований [16,17].

В работе показано, что задачи планирования мероприятий по кадровой безопасности целесообразно решать, как задачу 0–1 линейного программирования, позволяющую прозрачно сопоставлять эффект от снижения ущерба и стоимость внедрения при жёстких ресурсных ограничениях. По результатам расчёта оптимальный портфель включает четыре мероприятия (контроль/мониторинг, поведенческая аналитика, обучение сотрудников и мотивационно-организационные меры), тогда как инициативы с высокой стоимостью и недостаточно выраженным эффектом исключаются из программы. Предложенный подход формирует «живую» управленческую модель, которую можно регулярно актуализировать по данным инцидентов и пересчитывать при изменении бюджета и трудовых лимитов.

#### Список источников

1. Кузнецова Н.В. Кадровая безопасность организации. Сущность и механизм обеспечения. – Иркутск: Изд-во БГУЭП, 2019. – 285 с.
2. Шапошников В.Л. Современные модели и методы диагностики кадровой безопасности предприятия / В.Л. Шапошников, А.С. Артамкин, К.В. Хорошун // Вестник Российского университета кооперации, 2017. – № 4 (30). – С. 74-80. – URL: <https://cyberleninka.ru/article/n/sovremennyye-modeli-i-metody-dagnostiki-kadrovoy-bezopasnosti-predpriyatii>
3. Saxena N., Hayes E., Bertino E. et al. Impact and key challenges of insider threats on organizations and critical businesses. *Electronics*, 2020, vol. 9, no. 9, p. 1460, DOI: 10.3390/electronics9091460.
4. Alsowail R.A., Al-Shehari T. A multi-tiered framework for insider threat prevention. *Electronics*, 2021, vol. 10, no. 9, p. 1005, DOI: 10.3390/electronics10091005.
5. Software Engineering Institute, Carnegie Mellon University. Common sense guide to mitigating insider threats. 7th ed. Pittsburgh, Carnegie Mellon University, 2022, 65 p.
6. National Insider Threat Task Force. Insider threat guide. Washington, DC, National Counterintelligence and Security Center, Office of the Director of National Intelligence, 2024, 48 p.
7. NIST. Special publication 800-63B: digital identity guidelines – authentication and lifecycle management. Gaithersburg, National Institute of Standards and Technology, 2020, 79 p.
8. NIST. Cybersecurity framework (CSF). Gaithersburg, National Institute of Standards and Technology, 2023, 45 p.
9. Feng Y., Zhang L., Wang H. Recent advances in knapsack problem: a comprehensive review. *Neurocomputing*, 2025, vol. 650, p. 128073, DOI: 10.1016/j.neucom.2025.132135.
10. Mitchell S., O'Sullivan M., Dunning I. PuLP: a Python linear programming API. GitHub, 2015. Available at: <https://github.com/coin-or/pulp> (accessed: 01/05/2026).
11. Thapaliya S., Sharma A. Mitigating insider threats and data breaches: integration of behavioral analytics and NLP in DLP systems. *International Journal of Multidisciplinary Innovation Research*, 2024, vol. 2, no. 1, pp. 15-28.
12. Hoxhunt. Security awareness training: examples, metrics & best practices. Helsinki, Hoxhunt Ltd., 2024. Available at: <https://hoxhunt.com/guide/security-awareness-training> (accessed: 01/05/2026).
13. Inspired eLearning. Cyber security awareness training: creating an effective program. Tampa, Inspired eLearning, Inc., 2024. Available at: <https://inspiredelearning.com/security-awareness/our-approach/> (accessed: 01.05.2026).
14. Aslam T., Khan R., Usman M. Deep learning-based multi-factor authentication: a survey of biometric and smart card integration approaches. arXiv preprint arXiv:2510.05163, 2025, 42 p.
15. Identity Defined Security Alliance. All privileged access requires multi-factor authentication. Seattle, IDSA, 2023. Available at: <https://www.idsalliance.org/security-outcome/all-privileged-access-requires-multi-factor-authentication/> (accessed: 01/05/2026).
16. Testlify. The ultimate list of HR KPIs for success in 2025. San Francisco, Testlify, Inc., 2025. Available at: <https://testlify.com/hr-kpis/> (accessed: 01/05/2026).
17. The KPI Institute. Top 25 human resources KPIs – 2024 edition. Melbourne, The KPI Institute, 2024, 87 p.

*Туктарова Полина Андреевна. Кандидат экономических наук, доцент кафедры информатики и математического моделирования ФГБОУ ВО «Иркутский государственный аграрный университет имени А.А.*

Ежевского». AuthorID (RSCI): 944221. SPIN: 7889-8580. ORCID: 0000-0003-0773-3138, ptuktarova@gmail.com, Россия, Иркутская область, Иркутский район, поселок Молодежный.

**Мансурова Юлия Талгатовна.** Кандидат экономических наук, доцент кафедры экономики предпринимательства ФГБОУ ВО «Уфимский университет науки и технологий». AuthorID (RSCI): 1005445, SPIN: 4596-9811, ORCID: 0000-0001-7373-0344, mansurova.j@mail.ru. Россия, Республика Башкортостан, Уфа, ул. Карла Маркса 12.

**Ялтонская Диана Ильвировна.** Старший преподаватель кафедры экономики предпринимательства ФГБОУ ВО «Уфимский университет науки и технологий». AuthorID (RSCI): 1204681, SPIN: 8811-4946, ORCID: 0009-0007-4430-5657, diana.khamidullina.2016@mail.ru. Россия, Республика Башкортостан, Уфа, ул. Карла Маркса 12.

UDC 331.108.2

DOI:10.25729/ESI.2026.42.2.012

## Optimization of the enterprise personnel security program using discrete programming methods

Polina A. Tuktarova<sup>1</sup>, Yulia T. Mansurova<sup>2</sup>, Diana I. Yaltonskaya<sup>2</sup>

<sup>1</sup>Irkutsk State Agrarian University named after A.A. Ezhevsky, Russia, Irkutsk region, Irkutsk district, Molodezhny settlement, ptuktarova@gmail.com

<sup>2</sup>Ufa University of Science and Technology, Russia, Ufa

**Abstract.** This article focuses on optimizing an enterprise's personnel security program using discrete (0-1) linear programming methods under resource constraints. This approach is relevant because personnel are both a key asset and a potential source of internal threats, ranging from unintentional errors to deliberate violations leading to financial losses. The objective of this study is to develop a formalized model for selecting a set of personnel and information security measures that, given budget and labor limits, ensures the required reduction in integral risk and maximizes the expected economic impact. Binary indicators for program inclusion are used as decision variables, and the optimality criterion is defined as maximizing net annual savings (the difference between prevented damage and costs). The model incorporates constraints on funding, available man-hours, and an optional minimum cumulative impact constraint. Initial data was generated for six alternative measures (DLP/StaffCop monitoring, UEBA analytics, MFA enhancements for privileged users, information hygiene e-learning, KPIs/early warning, and an expanded benefits package) indicating cost, labor intensity, and expected loss reduction based on expert assessment and incident statistics. Practical testing was performed in the Python environment using the MILP (branch-and-bound) approach and demonstrates the optimal set of measures. The resulting solution ensures compliance with resource limits and the achievement of the target effect, while eliminating measures with the worst cost-to-benefit ratio. The scientific and practical significance of this work lies in the translation of high-quality management reasoning about personnel security into a reproducible optimization formulation suitable for recalculation with changes in prices, labor resources, and regulatory requirements.

**Keywords:** HR security, insider threats, discrete programming, 0-1 optimization, UEBA, DLP, MFA

### References

1. Kuznetsova N.V. Kadrovaya bezopasnost' organizatsii. Sushchnost' i mekhanizm obespecheniya [Personnel security of an organization. Essence and mechanism of provision]. Irkutsk, Baikal State University of Economics and Law Publ., 2019, 285 p.
2. Shaposhnikov V.L., Artamkin A.S., Khoroshun K.V. Sovremennyye modeli i metody diagnostiki kadrovoy bezopasnosti predpriyatiya [Modern models and methods for diagnosing personnel security of an enterprise]. Vestnik Rossiyskogo universiteta kooperatsii [Bulletin of the Russian university of cooperation], 2017, no. 4 (30), pp. 74-80. Available at: <https://cyberleninka.ru/article/n/sovremennyye-modeli-i-metody-diagnostiki-kadrovoy-bezopasnosti-predpriyatiya>.
3. Saxena N., Hayes E., Bertino E. et al. Impact and key challenges of insider threats on organizations and critical businesses. Electronics, 2020, vol. 9, no. 9, p. 1460, DOI: 10.3390/electronics9091460.

4. Alsowail R.A., Al-Shehari T. A multi-tiered framework for insider threat prevention. *Electronics*, 2021, vol. 10, no. 9, p. 1005, DOI: 10.3390/electronics10091005.
5. Software Engineering Institute, Carnegie Mellon University. Common sense guide to mitigating insider threats. 7th ed. Pittsburgh, Carnegie Mellon University, 2022, 65 p.
6. National Insider Threat Task Force. Insider threat guide. Washington, DC, National Counterintelligence and Security Center, Office of the Director of National Intelligence, 2024, 48 p.
7. NIST. Special publication 800-63B: digital identity guidelines – authentication and lifecycle management. Gaithersburg, National Institute of Standards and Technology, 2020, 79 p.
8. NIST. Cybersecurity framework (CSF). Gaithersburg, National Institute of Standards and Technology, 2023, 45 p.
9. Feng Y., Zhang L., Wang H. Recent advances in knapsack problem: a comprehensive review. *Neurocomputing*, 2025, vol. 650, p. 128073, DOI: 10.1016/j.neucom.2025.132135.
10. Mitchell S., O'Sullivan M., Dunning I. PuLP: a Python linear programming API. GitHub, 2015. Available at: <https://github.com/coin-or/pulp> (accessed: 01/05/2026).
11. Thapaliya S., Sharma A. Mitigating insider threats and data breaches: integration of behavioral analytics and NLP in DLP systems. *International Journal of Multidisciplinary Innovation Research*, 2024, vol. 2, no. 1, pp. 15-28.
12. Hoxhunt. Security awareness training: examples, metrics & best practices. Helsinki, Hoxhunt Ltd., 2024. Available at: <https://hoxhunt.com/guide/security-awareness-training> (accessed: 01/05/2026).
13. Inspired eLearning. Cyber security awareness training: creating an effective program. Tampa, Inspired eLearning, Inc., 2024. Available at: <https://inspiredelearning.com/security-awareness/our-approach/> (accessed: 01.05.2026).
14. Aslam T., Khan R., Usman M. Deep learning-based multi-factor authentication: a survey of biometric and smart card integration approaches. arXiv preprint arXiv:2510.05163, 2025, 42 p.
15. Identity Defined Security Alliance. All privileged access requires multi-factor authentication. Seattle, IDSA, 2023. Available at: <https://www.idsalliance.org/security-outcome/all-privileged-access-requires-multi-factor-authentication/> (accessed: 01/05/2026).
16. Testlify. The ultimate list of HR KPIs for success in 2025. San Francisco, Testlify, Inc., 2025. Available at: <https://testlify.com/hr-kpis/> (accessed: 01/05/2026).
17. The KPI Institute. Top 25 human resources KPIs – 2024 edition. Melbourne, The KPI Institute, 2024, 87 p.

**Tuktarova Polina Andreevna.** PhD in Economics of the Department of Computer Science and Mathematical Research, Irkutsk State Agrarian University named after A.A. Ezhevsky. AuthorID (RSCI): 944221, SPIN: 7889-8580, ORCID: 0000-0003-0773-3138, [ptuktarova@gmail.com](mailto:ptuktarova@gmail.com). Russia, Irkutsk region, Irkutsk district, Molodezhny settlement.

**Mansurova Yulia Talgatovna.** PhD in Economics of the Department of Economics of Entrepreneurship, Ufa University of Sciences and Technologies. AuthorID (RSCI): 1005445, SPIN: 4596-9811, ORCID: 0000-0001-7373-0344, [mansurova.j@mail.ru](mailto:mansurova.j@mail.ru). Russia, Republic of Bashkortostan, Ufa, st. Karl Marx 12.

**Yaltonskaya Diana Ilvirovna.** Senior lecturer of the Department of Economics of Entrepreneurship, Ufa University of Sciences and Technologies. AuthorID (RSCI): 1204681, SPIN: 8811-4946, ORCID: 0009-0007-4430-5657, [diana.khamidullina.2016@mail.ru](mailto:diana.khamidullina.2016@mail.ru), Russia, Republic of Bashkortostan, Ufa, st. Karl Marx 12.

Статья поступила в редакцию 08.01.2026; одобрена после рецензирования 06.05.2026; принята к публикации 11.05.2026.

The article was submitted 01/08/2026; approved after reviewing 05/06/2026; accepted for publication 05/11/2026.

УДК 004.89

DOI:10.25729/ESI.2026.42.2.013

## Интеллектуальные модели профориентации: структурный анализ и формальная постановка

Иващенко Анастасия Олеговна

Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Россия, Санкт-Петербург, *aok@dscs.pro*

**Аннотация.** Статья посвящена систематизации современных методов интеллектуальной профориентации и формализации единой вычислительной модели рекомендаций, интегрирующей психометрические данные, цифровой след, академические показатели и текстовые описания профессий. Актуальность исследования определяется переходом от изолированных диагностических методик к комплексным системам карьерной поддержки, способным учитывать разнообразие данных о пользователе и динамику профессиональных траекторий. Цель работы заключается в повышении качества и интерпретируемости профориентационных рекомендаций путём анализа существующих подходов и разработки математически строгой модели, объединяющей три ключевые задачи: реконструкцию профессиональных интересов, мультимодальное сопоставление предпочтений пользователя и профессии и ранжирование возможных траекторий. В статье представлен обзор исследований 2020–2025 гг., демонстрирующий рост точности и устойчивости методов профориентации при использовании ансамблевых алгоритмов, мультимодальных архитектур глубокого обучения и диалоговых LLM-систем. Показано, что объединение психометрических профилей, цифровой активности и текстовых описаний профессий позволяет существенно повысить качество рекомендаций при реконструкции интересов и подборе карьерных направлений. Научная новизна работы состоит в предложении единой теоретико-вычислительной модели интеллектуальной профориентации, которая задаёт общий математический каркас для разнородных подходов и позволяет интерпретировать многие существующие решения, как частные случаи. Модель включает формальное описание пользовательских и профессиональных данных, функцию восстановления RIASEC-профиля, параметризованную схему мультимодального сопоставления и интегральную функцию оптимизации, совместно обучающую все компоненты. Представленная формализация создаёт основу для разработки интерпретируемых, воспроизводимых и масштабируемых профориентационных систем.

**Ключевые слова:** профориентация, карьерный выбор, искусственный интеллект, модель Голланда (RIASEC), мультимодальные данные, цифровой след, интеллектуальные системы, психометрия

**Цитирование:** Иващенко А.О. Интеллектуальные модели профориентации: структурный анализ и формальная постановка / А.О. Иващенко // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 161-176. – DOI:10.25729/ESI.2026.42.2.013.

**Введение.** Современный рынок труда развивается при ускоренной цифровизации и трансформации профессиональных требований. В таких условиях от системы профориентации требуется не только разовая диагностика интересов, но и адаптивное сопровождение человека, учитывающее изменения его мотивации, компетенций и жизненных стратегий на разных этапах обучения и профессионального становления.

Как отмечает автор [1], в отличие от стран, где карьерное сопровождение интегрировано в национальные образовательные программы, отечественная профориентационная деятельность до недавнего времени имела фрагментарный характер и не опиралась на единую концептуальную модель. Однако, с 2023 года в России реализуется единая модель профориентационной деятельности («профминимум») и проект «Билет в будущее», а с 2024 года – Единая модель профориентации, охватывающая школьников 6-11-х классов и предусматривающая получение первой профессии к 2030 году. Эти инициативы формируют ранний профессиональный интерес и обеспечивают базовую информированность о возможных направлениях обучения, однако носят преимущественно диагностико-просветительский характер.

Отсутствие такого сопровождения непосредственно отражается на устойчивости профессиональных траекторий. По данным исследований, до 40 % молодых специалистов

меняют профессиональное направление в первые годы после завершения обучения [2]. Это подтверждает необходимость создания более комплексных инструментов профориентации, способных учитывать индивидуальные различия, связывать образовательные решения с потребностями рынка труда и обеспечивать непрерывную поддержку профессионального самоопределения.

Цель работы заключается в повышении качества и интерпретируемости профориентационных рекомендаций путём анализа существующих подходов и разработки математически строгой модели, объединяющей три ключевые задачи: реконструкцию профессиональных интересов, мультимодальное сопоставление предпочтений пользователя и профессии и ранжирование возможных траекторий.

Научная новизна заключается в формализации единой теоретико-вычислительной модели интеллектуальной профориентации, которая объединяет разнородные методы в общую математическую схему, задаёт их как частные случаи единого подхода и определяет согласованный набор вычислительных операций для восстановления интересов, мультимодального сопоставления и ранжирования профессиональных траекторий.

**1. Методология исследования.** Методология исследования сочетает систематический обзор современных подходов к интеллектуальной профориентации и последующую формализацию выявленных решений в виде единой вычислительной модели. Поисковая стратегия охватывала базы данных SpringerLink, IEEE Xplore, ACM Digital Library и РИНЦ за период 2020-2025 гг. В качестве ключевых запросов использовались комбинации терминов на русском и английском языках: профориентация, машинное обучение, career guidance, career recommendation, RIASEC, career decision, digital trace, social media profiling. Для расширения выборки применялся метод «снежного кома» по спискам литературы. Критерии включения: публикации, целью исследования которых являлось формирование профориентационных рекомендаций (подбор профессий/программ/траекторий), либо анализ возможности оценки психометрических характеристик и профессиональных интересов на основе цифрового следа.

Результаты систематизации использовались для выявления общих структурных элементов, ограничений и точек расхождения между существующими подходами. На основе этого анализа была разработана унифицированная формальная модель интеллектуальной профориентации.

**2. Психометрические модели профессиональных интересов.** Психометрические модели профессиональных интересов представляют собой формализованные схемы описания индивидуальных предпочтений, позволяющие представить личностные особенности в виде векторных признаков, пригодных для дальнейшего анализа методами машинного обучения и оптимального управления.

Классические психометрические методики (Е.А. Климова, Йоваши, методика «Якоря карьеры» Э. Шейна, карта интересов Голомштока, и др.) направлены на выявление устойчивых склонностей и ценностных ориентаций личности [3, 4]. Эти подходы позволяют выявить предрасположенности и ценности личности. Среди множества методик особое место занимает модель Дж. Голланда (RIASEC) [5, 6]. Эмпирические исследования подтверждают, что модель Дж. Голланда (RIASEC) обладает высокой предсказательной способностью при анализе профессиональных траекторий, удовлетворённости работой и образовательных исходов [7-9]. Структура модели описывает профессиональные интересы в виде шестимерного пространства типов личности – реалистичного (R), исследовательского (I), художественного (A), социального (S), предприимчивого (E) и конвенционального (C). Несоответствие между профилем личности и требованиями профессии – профессиональная

неконгруэнтность – может быть описано, как функция потерь, отражающая снижение удовлетворённости трудом и устойчивости карьеры [10-12].

Таким образом, психометрические модели, и прежде всего RIASEC, выступают базовым источником параметризации интересов в интеллектуальных профориентационных системах, обеспечивая формализованный вход для построения персонализированных рекомендаций.

**3. Роль социальных сетей в анализе психологических особенностей и профориентации.** Современные подходы к моделированию профессиональных интересов и карьерного выбора опираются на широкий спектр данных, отражающих личностные и поведенческие характеристики пользователей. Традиционно основу таких данных составляли самоотчёты и психометрические опросники, однако подобные методы трудоёмки и плохо масштабируются для больших выборок. В последние годы активно развиваются подходы, основанные на анализе цифрового следа, прежде всего данных социальных сетей, что открывает новые возможности для автоматического извлечения психологических признаков.

Существующие исследования показывают, что цифровой след позволяет предсказывать как общие личностные факторы, так и более узкие характеристики, например, такие, как уровень экстраверсии. В одном из наиболее масштабных ретроспективных исследований [13] показано, что цифровые предпочтения пользователей, выраженные через отметки «нравится» в социальных сетях, демонстрируют устойчивые корреляции с их личностными характеристиками по модели Big Five даже при анализе данных, накопленных за десятилетний период. В работе [14] продемонстрирована возможность прогнозирования 16 факторов опросника Кеттелла (16PF) на основе данных страниц пользователей социальной сети «ВКонтакте» с применением методов машинного обучения; наилучшие результаты показал алгоритм Random Forest (Accuracy до 0.87). В исследовании [15] реализована нейросетевая архитектура на основе LSTM для определения типов личности по системе Майерс-Бриггс (MBTI), обеспечившая точность 86,31%. В работах [16, 17] проведено сравнительное исследование алгоритмов бустинга при классификации 16PF и показана их высокая устойчивость и обобщающую способность. В работе [18] предложена интегрированная модель, совмещающая текстовые и поведенческие признаки для прогнозирования дихотомии экстраверсии-интроверсии по публикациям пользователей в социальных сетях; использование ансамблевых алгоритмов (XGBoost, LightGBM, Random Forest) позволило достичь F1-score=0.82, что подтверждает эффективность подходов, объединяющих лингвистический и поведенческий анализ.

Подтверждения релевантности цифровых следов для оценки профессиональных интересов получены в работах [19, 20]. Так в [19] показано наличие устойчивых корреляций между профориентационными предпочтениями пользователей и тематиками сообществ, на которые они подписаны. Аналогично в [20] авторы предложили способ количественного сопоставления ведущих интересов личности в терминах RIASEC-профиля на основе анализа контента аккаунтов, показав возможность реконструкции доминирующих типов интересов по цифровым признакам. Дальнейшее развитие этого направления представлено в работах [21, 22], где технологии больших данных и анализ цифрового следа используются для выявления паттернов интересов профессиональных сообществ и последующей профориентации школьников на медицинскую и педагогическую деятельность.

Таким образом, источники на основе цифрового следа образуют масштабируемую альтернативу анкетированию для извлечения психологически и профессионально значимых признаков.

**4. Методы искусственного интеллекта для профориентационных рекомендаций.** Таблица 1 суммирует основные характеристики рассмотренных исследований в области

интеллектуальных систем профориентации за период 2020-2025 гг., включая тип исходных данных, используемые методы и ключевые результаты в терминах качества рекомендаций. В таблицу включены пять классов решений, которые далее анализируются в тексте: (1) модели, основанные на цифровом следе пользователей социальных сетей; (2) системы, использующие академические и кадровые данные; (3) эвристические и нечёткие методы; (4) мультимодальные и NLP-ориентированные архитектуры; (5) LLM-ориентированные подходы. Такая классификация отражает переход от работы с отдельными источниками данных к комплексным системам, интегрирующим разнородные модальности.

**Таблица 1.** Характеристики исследований в области интеллектуальных систем профориентации (2020-2025 гг.)

Автор, год, ссылка	Данные	Метод/Модель	Метрика	Ключевой вклад
Анализ цифрового следа				
Erbay et al., 2024 [23]	10 455 текстовых постов (4 профессии, 80/20 split)	LDA + LSTM/GRU (3 слоя, embedding 100)	GRU: Acc = 0.871, F1 = 0.870	Идентификация профессий по текстовым постам; показана связь тематических признаков и RIASEC-кодов
Kiselev et al., 2020 [24]	VK: 1252 профиля, подписки ( $\approx 136$ /польз.), исключены профили <10 подписок и равные интересы	СВ бинарные классификаторы по 10 сферам (5-fold CV)	AUC-ROC: 0.68 (медиа) – 0.85 (производство); среднее 0.70–0.80. Лучшее: образование/IT (0.83), производство (0.85)	Восстановление профилей интересов по подпискам VK для предсказания профессиональных сфер
Забокрицкая и др., 2022 [25]	VK: 47 672 абитуриента, 138 программ, демография, ценности	LR, вектор интересов (подписки, контент, связи)	Поведенческие KPI: конверсия 26.8 %, переходы 32 %	Веб-платформа Wizard для рекомендаций образовательных программ на основе анализа VK-профилей
Chekalev et al., 2024 [26]	VK: $n \approx 1200$ (результаты RIASEC + темы сообществ)	XGB, СВ, LR, DT многоклассов. Классификация	XGB: F1-macro = 0.252, F1-weighted = 0.307	Модель предсказания типов RIASEC по тематике сообществ VK; подтверждена применимость ML к поведенческим данным
Применение машинного обучения к кадровым и образовательным данным				
Panthee et al., 2023 [27]	Big Five (Kaggle, 1 015 342 ответов) + VAK (GDS)	RF/DT (Big Five), SVM/XGB/DT/RF (VAK)	RF: Acc = 0.9114; SVM: Acc = 0.905	Веб-система рекомендаций на основе Big Five и типа восприятия информации VAK для профориентации студентов
Kamal et al., 2021 [28]	309 респондентов (RIASEC + Multiple Intelligences) (80/20 split, SMOTE)	RF, XGB (Grid Search, Stratified K-Fold)	RF: Acc = 0.986, F1 = 0.98; SVM: Acc = 0.963	Сочетание RIASEC и теории множественного интеллекта в веб-системе для выбора карьеры
Reddy et al., 2022 [29]	Kaggle: 20 000 записей (оценки, интересы, личностные факторы), 75/25 split	DT, RF, Voting Classifier	RF: Acc = 0.92, Prec = 0.94, Sens = 0.86; Voting = 0.89	Ансамблевое обучение для профориентации в IT; интеграция E-learning и оценок компетенций
Padma et al., 2025 [30]	Реальные и синтетические данные (500)	DT, NB, RF, SVM	RF: Acc = 0.911; DT: Acc = 0.783	Интеллектуальная система профориентации на основе

	записей): академические данные, навыки			машинного обучения для Big Five и VAK
Yang & Chang, 2023 [31]	≈4000 студентов (демография, GPA, соцмедиа-индекс (n=1424 статей))	DT, ANN, SVM, LR, k-NN, NB	Acc = 0.9785 (ANN на подвыборках), Карра: 0.96; незначительное улучшение от соцмедиа	Прогнозирование карьерных решений с интеграцией академических и соцмедиа-данных
Song et al., 2022 [33]	N=81 267 (PGI-Mini + O*NET)	Ансамбль (NN, kNN, Elastic Net, RF)	Hit Rate (Top-1): 0.34 (↑ с 0.28), Profile Corr: 0.44 (↑ с 0.23)	Интеграция ML в O*NET; улучшение предсказания RIASEC-профилей по сравнению с классическим сопоставлением
Gülten & Baraçlı, 2024 [32]	HR-данные (4890 сотрудников, 29 признаков) (75/25 split)	kNN, RF, GB, SVM	GB: Acc = 0.902, F1 = 0.903; RF: Acc = 0.853, F1 = 0.851	Прогностическая модель для HR-карьерного планирования в госорганизациях
Эвристические и нечёткие методы				
Сергушичева & Давыдова, 2020 [34]	Оценки по предметам + профессиограммы (компетенции, дисциплины)	Генетический алгоритм (кроссовер, мутация, селекция), fitness-функция	Fitness (E→1), суммарный F (макс. 500); топ-5 профессий с % успеха	Автоматизация подбора профессий по школьным оценкам с эволюционным отбором
Тарасова & Комарова, 2024 [35]	Школьные профили (опросы, оценки, тесты), 29 групп профессий (Атлас 3.0), векторы из 11 компетенций	Матричная модель корреляций + генетический алгоритм (fitness-оптимизация)	Эвристический fitness (без ML-метрик)	Самоадаптирующаяся система для подбора профессий с учетом компетенций и обратной связи
Cheng Y., 2025 [36]	Реальные и синтетические данные: анкеты студентов, профили LinkedIn, успеваемость, социальные данные; мультимодальные источники (текст, изображения, аудио)	Гибридная архитектура: Fuzzy Logic + Deep Learning (CNN, LSTM, Transformer) + Reinforcement Learning	Acc = 0.88; Recall = 0.82; F1 = 0.85; RMSE = 0.22	Разработана микросервисная платформа профориентации с нечеткой обработкой интересов и адаптивным онлайн-обучением; доказано повышение точности и персонализации рекомендаций
Мультимодальные и NLP модели				
José-García et al., 2023 (C3-IoC) [37]	IT-вакансии: 22 359 (195 skills) + O*NET (381 ролей, 142 навыков)	Word2Vec + Sim + RCA + Louvain + регрессия	SRP@10 = 0.40–1.00, Acc = 0.80–1.00	Система C3-IoC: визуализация навыков и карьер в IT на основе сетевого анализа
Li et al., 2025 [38]	10 выпускников: резюме, фото, поведенческие данные	Мультимодальны й DL (NLP: TF-IDF/Word2Vec; CNN: VGG/ResNet; LSTM)	Acc = 0.90–0.95, F1 = 0.90–0.95 (+ 0.15 при мультимодальност и)	Мультимодальная модель для рекомендаций с интеграцией текста, изображений и поведения

Kumbhar et al., 2023 [39]	Корпус Q&A по профориентации (ручная разметка)	Гибрид RNN/LSTM + NLP	Acc = 0.9933, F1 = 0.9844	Чат-бот для адаптированного под пользователя карьерного консультирования
LLM-ориентированные подходы в профориентации				
Wang Q. et al. (2025) [40]	Реальные данные Walmart: 10k пользователей, 932 тыс. записей о смене работы; граф People.AI (83 млн связей)	LLM-powered агентная архитектура (AdaptJobRec) с механизмом определения сложности и планировщиком задач	Hit@10=0.3176; NDCG@10=0.081; MAP@10=0.037; Latency↓53%	Агентная LLM-система для карьерных рекомендаций; примененная к промышленным данным Walmart
Ramesh V. et al. (2025) [41]	Собственные данные ≈150 пользователей: анкеты (образование, навыки, цели), результаты тестов, диалоги с чат-ботом GPT-4o, рейтинги полезности рекомендаций, интеграция с API курсов (Coursera, Udemu, NPTEL)	GPT-4o (1.8 трлн параметров, multimodal AI) + Predictive Analytics + Feedback Loop	Acc = 0.941, Response Time = 0.320 с, User Feedback (качеств.)	Создана мультимодальная AI-платформа профориентации, объединяющая LLM-анализ, адаптивные тесты и API интеграции с образовательными платформами
Kulugh et al. (2025) [42]	Профили пользователей (soft skills, hard skills, интересы), 3 тестовых синтетических сценария; UAT-оценки; API-лог запросов	Интеграция RIASEC + SCT; генеративная модель Llama API; rule-based логика; Waterfall-архитектура; Supabase backend	Успешное прохождение unit tests; API latency (8464 ms)	Разработка архитектуры AI-платформы профориентации на основе RIASEC+SCT; интеграция Llama API в процесс рекомендаций; инженерная валидизация
Shahzada et al. (2025) [43]	50 пользователей (студенты, выпускники, специалисты); ввод навыков, психометрии, целей; skill-gap профили	LLaMA-3.1-8B-Instant; генеративная архитектура; комплексная система рекомендаций + XAI + fairness	Relevance = 0.923; SUS = 0.915; Actionability = 0.874; Accuracy рекомендаций = 0.87	LLM-ориентированная карьерная система с интеграцией психометрии, рынка труда, XAI и skill-gap анализа; высокая релевантность и практическая применимость
Arya et al., 2025 [44]	Ответы RIASEC; OCR-оценки из табеля; тестовые профили	RIASEC-анализ + CNN-OCR + LLM (prompt engineering)	Tesseract 0.47; EasyOCR 0.55; Doctr 0.57	Интегрированная система на основе RIASEC, OCR и LLM для персонализированных карьерных рекомендаций

Расшифровка сокращений: Acc – Accuracy; F1 – F1-score; RF – Random Forest; SVM – Support Vector Machine; DT – Decision Tree; LSTM – Long Short-Term Memory; GRU – Gated Recurrent Unit; DL – Deep Learning; NN – Neural Network; LR – Logistic Regression; k-NN – k-Nearest Neighbors; NB – Naïve Bayes; XGB – XGBoost; Prec – Precision; Sens – Sensitivity; SRP@k – Success Rate Percentage at k; Corr – Correlation.

*Подходы, основанные на цифровом следе.* Методы анализа цифрового поведения и подписок в социальных сетях позволяют реконструировать профессиональные интересы и профили пользователей. Работы в этом направлении показывают, что ML-модели (CatBoost, XGBoost, тематическое моделирование, RNN) способны выделять профессиональные сообщества, предсказывать тип личности и формировать первичные карьерные рекомендации [23-26]. Точность таких систем варьируется в зависимости от платформы и набора признаков, достигая высоких значений для сфер образования, медицины и IT.

*Применение машинного обучения к кадровым и образовательным данным.* Помимо цифрового следа, значительное развитие получили подходы, использующие академические и кадровые данные обучающихся и сотрудников. Большинство исследований демонстрируют, что классические ML-модели – Random Forest, Gradient Boosting, SVM, нейронные сети – стабильно превосходят традиционные методы сопоставления профилей при прогнозировании профессиональных интересов и карьерных решений.

Работы на крупных выборках демонстрируют достижение высокой точности классификации образовательных траекторий, а также успешное интегрирование личностных характеристик, успеваемости и демографических данных в единые прогнозные модели [27-31]. Анализ корпоративных HR-данных подтверждает аналогичную тенденцию: ансамблевые модели обеспечивают точность 0.94–0.98 при прогнозировании должностных категорий [32]. Отдельный класс решений связан с использованием профилей компетенций O\*NET. Так, в работе [33] авторы показали, что внедрение методов машинного обучения в традиционную систему профилей O\*NET позволяет повысить качество сопоставления должностей и профессиональных интересов: показатель Hit Rate (Top-1) увеличился до 0.34, а корреляция профилей – до 0.44.

Совокупность этих исследований демонстрирует, что ансамблевые алгоритмы машинного обучения устойчиво повышают точность анализа академических и HR-данных, формируя основу для персонализированных систем профориентации и автоматизированного планирования карьерных траекторий.

*Эвристические и нечёткие методы.* Помимо статистических и нейросетевых моделей, в ряде работ рассматриваются эвристические подходы к формированию карьерных рекомендаций. Эволюционные алгоритмы используются для поиска оптимальных вариантов профессий с учётом предпочтений и компетентностных требований: генетические схемы позволяют формировать ограниченный набор (Top-5) релевантных направлений и адаптировать критерии отбора под обратную связь пользователя [34, 35].

Другим направлением являются гибридные архитектуры, объединяющие нечёткую логику и методы глубокого обучения. Такие системы позволяют работать с субъективными описаниями интересов, учитывать неопределённость пользовательских ответов и интегрировать разнородные признаки [36].

*Мультимодальные и NLP-ориентированные решения.* Современные системы профориентации всё чаще объединяют разнородные источники данных – тексты вакансий и резюме, онтологии навыков, визуальные материалы и поведенческие сигналы. Исследования показывают, что комбинирование этих источников позволяет существенно повысить точность рекомендаций.

Показано, что применение NLP-моделей и методов сетевого анализа к текстовым данным позволило выявить структуру профессиональных ролей и визуализировать взаимосвязи навыков [37].

Мультимодальные архитектуры, объединяющие NLP, CNN и LSTM, учитывают профессиональные, визуальные и поведенческие аспекты профиля пользователя, обеспечивая прирост точности по сравнению с однотипными моделями и совпадение рекомендаций с реальными интересами на уровне 90–95% [38]. Отдельный класс решений связан с диалоговыми системами, использующими классические нейросетевые NLP-подходы. Такие чат-боты опираются на RNN/LSTM и векторные представления текста, обеспечивая интерактивный подбор профессий, но оставаясь ограниченными фиксированным набором сценариев и отсутствием контекстной адаптации [39].

*LLM-ориентированные подходы в профориентации.* Использование больших языковых моделей стало новым этапом развития интеллектуальных профориентационных систем. Современные решения включают агентные и диалоговые архитектуры, способные интерпретировать запросы пользователей и формировать персонализированные рекомендации. Примером является LLM-центричная система [40], использующая механизмы анализа сложности запросов, релевантную память и планирование подзадач для повышения качества ранжирования вакансий.

Генеративные модели активно интегрируются с психометрическими и образовательными данными: работы [41, 42] демонстрируют применение GPT- и LLaMA-моделей для интерпретации RIASEC-профилей и построения карьерных траекторий. Более комплексный подход реализован в системе CAREERLLAMA [43] объединяющей психометрию, анализ навыков и подбор обучающих маршрутов. В исследовании [44] LLM дополнены OCR-моделями, что позволяет обрабатывать академические данные и формировать рекомендации в диалоговом режиме.

В совокупности эти разработки показывают, что LLM обеспечивают гибкую интеграцию психометрических, текстовых и образовательных признаков, повышая адаптивность и персонализацию профориентационных рекомендаций.

**5. Формальная постановка задачи интеллектуальной профориентации.** Согласно проведённому обзору, интеллектуальная система профориентации может опираться на разнородные данные о пользователях, включая психометрические показатели, цифровой след, академические и кадровые характеристики, а также текстовые описания. Чтобы представить эти данные в едином формате и обеспечить возможность вычислительной обработки, введём общую формальную модель.

Пусть задано множество пользователей  $U = \{U_1, \dots, U_N\}$ . Для пользователя  $U_i$  определим:  $R_i \in \mathbf{R}^6$ ; – вектор профессиональных интересов RIASEC (может быть неизвестен для части пользователей),  $X_i = (D_i, E_i, T_i)$  – дополнительные данные о пользователе, где  $D_i \in \mathbf{R}^{d_s}$  – признаки цифрового следа,  $E_i \in \mathbf{R}^{d_e}$  – академические и HR-признаки,  $T_i$  – текстовая информация (описания, резюме, диалог с ботом и т.п.).

Поскольку доступность этих модальностей может различаться, все дополнительные данные приводятся к единому мультимодальному эмбедингу пользователя:  $Z_i = \psi(X_i) \in Z = \mathbf{R}^{d_z}$ , где  $\psi$  – обучаемое или фиксированное отображение, обрабатывающее доступные признаки и формирующее эмбединг профиля пользователя. Таким образом, итоговое описание пользователя задаётся парой  $U_i = (R_i, Z_i)$ .

*Задача 1. Восстановление вектора профессиональных интересов.* Поскольку психометрический профиль  $R_i$  известен не всегда, требуется оценить его по мультимодальному представлению  $Z_i$ . Построим отображение:  $f_\theta: Z \rightarrow \mathbb{R}^6$ , где  $Z$  – пространство мультимодальных представлений пользователей, а  $\theta$  – параметры модели восстановления.

Оценка параметров  $\theta$  осуществляется по пользователям с известными профилями RIASEC:

$$\theta^* = \arg \min_{\theta} \sum_{i \in L_R} L_R(R_i, f_\theta(Z_i)),$$

где  $L_R$  – множество пользователей с доступным RIASEC-профилем,  $L_R$  – функция ошибки (например, RMSE). После оценки параметров получаем обученную модель  $\hat{f} = f_{\theta^*}$ .

Тогда восстановленный профиль будет иметь вид:  $R_i = \hat{f}(Z_i)$ , а итоговый вектор интересов определяться как:  $R_i^* = \begin{cases} R_i, & i \in L_R \\ R_i, & i \notin L_R \end{cases}$ .

*Задача 2. Мультимодальное соответствие «пользователь – профессия».* Обозначим множество профессий (или должностей, либо образовательных направлений), как  $P = \{P_1, \dots, P_K\}$ . Для каждой профессии  $P_j \in P$  зададим двухкомпонентный векторный профиль:  $P_j^R \in \mathbb{R}^6$  – вектор профессиональных интересов RIASEC, который соответствует данной профессии,  $P_j^Z \in Z$  – вектор-эмбединг текстового описания профессии. Предполагается, что в практической реализации эмбединги профессий приводятся к той же размерности, что и мультимодальные представления пользователя.

Определим частные функции сходства:

– Психометрическое соответствие  $S_R(U_i, P_j) = \cos(R_i^*, P_j^R) = \frac{\langle R_i^*, P_j^R \rangle}{\|R_i^*\| \cdot \|P_j^R\|}$ .

– Семантическое соответствие:  $S_Z(U_i, P_j) = h(Z_i, P_j^Z)$ , где  $h: Z^2 \rightarrow \mathbb{R}$  – функция сходства (например, скалярное произведение, косинусное расстояние).

Введём параметризованную функцию соответствия между предпочтениями пользователя и профессией:  $S_\varphi(U_i, P_j) = g_\varphi(S_R(U_i, P_j), S_Z(U_i, P_j))$ , где  $g_\varphi: \mathbb{R}^2 \rightarrow \mathbb{R}$  – обучаемая функция, параметры которой оптимизируются по разметке релевантности.

*Интегральная оптимизационная модель.* Чтобы обучить функции  $f_\theta$  и  $S_\varphi$ , введём разметку релевантности профессий предпочтениям пользователя. Пусть  $\Omega \subseteq \{1, \dots, N\} \times \{1, \dots, K\}$  – множество пар  $(i, j)$ , для которых известна метка релевантности:  $y_{ij}$  (бинарная, ранговая или вероятностная). Обозначим два семейства параметров:

$\theta$  – параметры функции восстановления психометрического профиля  $f_\theta$ ;

$\varphi$  – параметры мультимодальной функции соответствия  $S_\varphi$ .

Определим интегральную функцию потерь:

$$L(\theta, \varphi) = \underbrace{\sum_{i \in L_R} L_R(R_i, f_\theta(Z_i))}_{\text{ошибка восстановления RIASEC}} + \lambda \underbrace{\sum_{(i,j) \in \Omega} L_S(S_\varphi(U_i, P_j), y_{ij})}_{\text{ошибка сопоставления профессии}}$$

где  $\lambda$  – гиперпараметр, задающий относительную важность задачи восстановления профиля по сравнению с задачей обучения рекомендаций.

Итоговая оптимизационная задача формулируется как:  $(\theta^*, \varphi^*) = \arg \min_{\theta, \varphi} L(\theta, \varphi; \lambda)$ .

*Задача 3: Ранжирование и выбор рекомендуемой траектории.* После обучения итоговая функция соответствия  $S_{\varphi^*}(U_i, P_j)$  используется для построения индивидуальных рекомендаций пользователю  $U_i$ . Пусть  $\text{score}_i(j) = S_{\varphi^*}(U_i, P_j)$  – функция оценок профессий. Определим перестановку индексов профессий  $\pi_i = \text{argsort}_{j \in \{1, \dots, K\}} \text{score}_i(j)$ . Тогда индивидуальный ранжированный список профессий для пользователя  $U_i$  будет иметь вид:  $\Pi_i = (P_{\pi_i(1)}, P_{\pi_i(2)}, \dots, P_{\pi_i(K)})$ .

**Обсуждение.** Предложенная формальная постановка рассматривает интеллектуальную профориентацию как единую вычислительную задачу, объединяющую три ключевых этапа: реконструкцию психометрического профиля, мультимодальное сопоставление пользователя и профессии и последующее ранжирование возможных траекторий. Такая структура позволяет описать разнородные подходы, представленные в современной литературе, в рамках единой модели и сравнивать их по общим принципам.

В такой формализации модели, ориентированные на извлечение психометрических характеристик из цифрового следа [23–26] интерпретируются, как частные случаи задачи восстановления  $R_i^*$ . Системы, в которых сначала оцениваются профессиональные интересы, а затем формируются рекомендации [27–33], соответствуют последовательному решению задач реконструкции и сопоставления. Мультимодальные архитектуры, использующие текстовые, визуальные и поведенческие признаки [37–39], интегрируются в общую модель через уточнение функции семантического соответствия и расширение набора входных модальностей. В свою очередь, исследования, использующие LLM-архитектуры [40–44], расширяют класс функций сопоставления и позволяют обучать модель на более гибких и неструктурированных данных. Таким образом, используемые в современных исследованиях методы могут быть объединены в единую вычислительную схему. Формализация также совместима с основными метриками, применяемыми в исследованиях.

Перспективным направлением развития является переход от статической постановки к динамической, в которой интересы пользователя, компетенции и карьерные решения рассматриваются, как временные ряды. Такая модель позволила бы учитывать траектории обучения, изменения мотивации и переходы между профессиональными ролями. Однако реализация подобного подхода требует расширенных лонгитюдных данных, что пока ограничивает распространение динамических моделей.

**Заключение.** Проведённый обзор демонстрирует переход от отдельных психометрических методик к интеллектуальным профориентационным системам, интегрирующим психометрические, цифровые, академические и кадровые данные. Показано, что использование формализованных векторных представлений профессиональных интересов в сочетании с методами машинного обучения улучшает релевантность рекомендаций. Современные решения, основанные на ансамблевых, мультимодальных и диалоговых архитектурах, обеспечивают существенный прирост качества и подтверждают значимость объединения текстовых, визуальных и поведенческих признаков.

Научная новизна и оригинальность данного исследования состоят в предложении единой вычислительной модели интеллектуальной профориентации, которая объединяет три ключевые задачи – восстановление профессиональных интересов, мультимодальное

сопоставление и ранжирование – в единую оптимизационную схему. Такой подход позволяет интерпретировать существующие методы, как частные случаи общей модели и обеспечивает обобщённый математический аппарат для анализа и сравнения современных систем профориентации.

Значимость исследования заключается в формировании единой теоретико-вычислительной основы, которая позволяет сравнивать разнородные методы, выявлять их ограничения и строить более интерпретируемые, воспроизводимые и масштабируемые профориентационные системы.

**Благодарности.** Работа выполнена в рамках проекта по государственному заданию СПб ФИЦ РАН № FFZF-2025-0006.

#### Список источников

1. Ивакина М.В. Сравнительный анализ систем профориентационной работы в России и за рубежом / М.В. Ивакина // Педагогическое образование в России, 2022. – № 3. – С. 85–94.
2. Горбунова Н.В. От выбора профессии к профессиональной карьере и успеху в жизни / Н.В. Горбунова // Гуманитарные науки, 2016. – № 2 (34). – С. 28–33.
3. Пряжникова Е.Ю. Профориентация: учеб. пособие для студ. высш. учеб. заведений / Е.Ю. Пряжникова, Н.С. Пряжников. – М.: Академия, 2006. – 496 с.
4. Бендюков М.А. Ступени карьеры: азбука профориентации / М.А. Бендюков, И.Л. Соломин. – СПб.: Речь, 2006. – 240 с.
5. Holland J.L. Making Vocational Choices: A Theory of Vocational Personalities and Work Environments. Englewood Cliffs (NJ), Prentice-Hall, 1985.
6. Воробьев А.Н. Опросник профессиональных предпочтений: руководство / А.Н. Воробьев, И.Г. Сенин, В.И. Чирков. – 3-е изд. – М.: Когито-Центр, 2001. – 20 с.
7. Batista J.S., Gondim S.M.G. Personality and Person–Work Environment Fit: A Study Based on the RIASEC Model, International Journal of Environmental Research and Public Health, 2022, vol. 20, no. 1, p. 719, DOI: 10.3390/ijerph20010719.
8. Chu C., Hoff K.A., Liu Z., et al. Interest Fit Beyond the RIASEC: The Comprehensive Assessment of Basic Interests – O\*NET (CABIN-NET). Journal of Career Assessment, 2025, article 10690727251322520, DOI: 10.1177/10690727251322520.
9. Roemer L., Lewis P., Rounds J. The German O\*NET Interest Profiler Short Form. Psychological Test Adaptation and Development, 2023, vol. 4, no. 1, pp. 156–167, DOI: 10.1027/2698-1866/a000048.
10. Englert B. The Incongruity of Misfit: A Systematic Literature Review and Future Research Agenda. Human Relations, 2024, vol. 77, no. 9, pp. 1306–1332, DOI: 10.1177/00187267231187751.
11. Sun Y. What Is This Thing Called Misfit? A Systematic Review into How Employee Misfit Has Been Defined and Researched. Management Review Quarterly, 2024, pp. 1–64, DOI: 10.1007/s11301-024-00461-w.
12. Ertl B., Hartmann F.G., Wunderlich A. Impact of Interest Congruence on Study Outcomes, Frontiers in Psychology, 2022, vol. 13, article 816620, DOI: 10.3389/fpsyg.2022.816620.
13. Marengo D., Settanni M. Examining the Postdictive Validity of Self-Report Big Five Personality Traits with Objective Recordings of Online Behaviors: A Ten-Year Retrospective Study Using Facebook Page Likes. Heliyon, 2024, vol. 10, no. 12, DOI: 10.1016/j.heliyon.2024.e32746.
14. Oliseenko V.D., Abramov M.V. Predicting the Results of the 16-Factor R. Cattell Test Based on the Analysis of Text Posts of Social Network Users, Scientific and Technical Journal of Information Technologies. Mechanics and Optics, 2023, vol. 148, no. 2, pp. 279–288, DOI: 10.17586/2226-1494-2023-23-2-279-288.
15. Самойлова Л. Прогнозирование личностных характеристик MBTI с использованием рекуррентной нейронной сети LSTM и текстовых данных социальных сетей / Л. Самойлова, В.М. Даниловский // Вестник науки, 2024. – Т. 4. – № 6 (75). – С. 1176–1184.
16. Khan A., Maneria H., Kumar A., et al. A Comprehensive Examination of Machine Learning Models in Predicting 16 Personality Traits. Doctoral Symposium on Computational Intelligence, Singapore, Springer Nature, 2024, pp. 1–13, DOI: 10.1007/978-981-97-6726-7\_1.
17. Goyal C., Kemni D., Pandey M. An Evaluation of Machine Learning Techniques for Personality Classification Using the Myers–Briggs Assessment. International Conference on Innovative Computing and Communication, Singapore, Springer Nature, 2024, pp. 555–570, DOI: 10.1007/978-981-97-3591-4\_42.

18. Yang Q., Farseev A., Nikolenko S., Filchenkov A. Do We Behave Differently on Twitter and Facebook: Multi-View Social Network User Personality Profiling for Content Recommendation. *Frontiers in Big Data*, 2022, vol. 5, article 931206, DOI: 10.3389/fdata.2022.931206.
19. Хлобыстова А.О. Исследование тенденций взаимосвязи между профориентационными предпочтениями пользователей и их цифровыми следами в социальной сети / А.О. Хлобыстова, М.В. Абрамов, В.Ф. Столярова // *Научно-технический вестник информационных технологий, механики и оптики*, 2023. – Т. 23. – № 3. – С. 564–574. – DOI: 10.17586/2226-1494-2023-23-3-564-574.
20. Khlobystova A.O., Abramov M.V., Stoliarova V.F. Characterization of the Person’s Leading Interests in Terms of RIASEC Scores, *International Conference on Intelligent Information Technologies for Industry*. Cham, Springer Nature Switzerland, 2023, pp. 281–290, DOI: 10.1007/978-3-031-43789-2\_26.
21. Малахов В.В. Использование больших данных в практиках профориентации школьников на медицинскую профессию / В.В. Малахов, Л.Г. Смышляева, А.Н. Мелентьева, и др. // *Перспективы науки и образования*, 2023. – № 6 (66). – С. 516–531. – DOI: 10.32744/pse.2023.6.30.
22. Малахов В.В. Особенности использования технологий больших данных в практиках профориентации школьников на педагогическую деятельность / В.В. Малахов // *Научно-педагогическое обозрение*, 2025. – № 1 (59). – С. 56–65. – DOI: 10.23951/2307-6127-2025-1-56-65.
23. Erbay H., Yurttakal A.H., Dağıstanlı Ö., et al. Advising Career Choice Through Tweeter Data. *Multimedia Tools and Applications*, 2024, pp. 1–17, DOI: 10.1007/s11042-024-20440-3.
24. Kiselev P., Kiselev B., Matsuta V., et al. Career Guidance Based on Machine Learning: Social Networks in Professional Identity Construction. *Procedia Computer Science*, 2020, vol. 169, pp. 158–163, DOI: 10.1016/j.procs.2020.02.128.
25. Забокрицкая Л.Д. Wizard: интеллектуальная система профориентации для абитуриентов на основе машинного обучения / Л.Д. Забокрицкая, Т.А. Орешкина, И.Н. Обабков, и др. // *Вестник Томского государственного университета*, 2022. – № 485. – С. 217–225.
26. Chekalev A., Khlobystova A., Abramov M. Community Theme Analyser: Predicting Career Guidance in Online Social Networks. *Proceedings of the Eighth International Scientific Conference “Intelligent Information Technologies for Industry” (IITI’24)*, vol. 2, IITI 2024, pp. 153–162, DOI: 10.1007/978-3-031-77411-9\_14.
27. Panthee S., Rajkarnikar S., Begum R. Career Guidance System Using Machine Learning. *Journal of Advanced College of Engineering and Management*, 2023, vol. 8, no. 2, pp. 10–19, DOI: 10.3126/jacem.v8i2.55947.
28. Kamal A., Naushad B., Rafiq H., et al. Smart Career Guidance System. *2021 4th International Conference on Computing & Information Sciences (ICCIS)*, IEEE, 2021, pp. 1–7, DOI: 10.1109/ICCIS54243.2021.9676408.
29. Reddy K., Reddy M.A., Kaur V., et al. Career Guidance System Using Ensemble Learning. *Proceedings of the Advancement in Electronics & Communication Engineering*, 2022, pp. 33–39, DOI: 10.2139/ssrn.4157249.
30. Padma E., Sowdharshini P., Shanmugapriya P., et al. Career Guidance System for Students Using Machine Learning, *Challenges in Information, Communication and Computing Technology*. CRC Press, 2025, pp. 666–671, DOI: 10.1201/9781003559092-115.
31. Yang T.C., Chang C.Y. Using Institutional Data and Messages on Social Media to Predict the Career Decisions of University Students: A Data-Driven Approach. *Education and Information Technologies*, 2023, vol. 28, no. 1, pp. 1117–1139, DOI: 10.1007/s10639-022-11185-3.
32. Gülten H., Baraçlı H. A Machine Learning-Based Forecast Model for Career Planning in Human Resource Management: A Case Study of the Turkish Post Corporation. *Applied Sciences*, 2024, vol. 14, no. 15, article 6679, DOI: 10.3390/app14156679.
33. Song Q.C., Shin H.J., Tang C., et al. Investigating Machine Learning’s Capacity to Enhance the Prediction of Career Choices. *Personnel Psychology*, 2022, vol. 77, no. 2, pp. 295–319, DOI: 10.1111/peps.12529.
34. Сергушичева А.П. Построение компьютерной системы профориентации выпускников средних образовательных заведений на базе генетического алгоритма / А.П. Сергушичева, Е.Н. Давыдова // *Открытое образование*, 2020. – № 3. – С. 33–43. – DOI: 10.21686/1818-4243-2020-3-33-43.
35. Тарасова А.С. Проектирование рекомендательной системы профориентации школьников средствами машинного обучения / А.С. Тарасова, Э.П. Комарова // *Гуманитарные исследования. Педагогика и психология*, 2024. – № 17. – С. 7–14.
36. Cheng Y. Development of a Career Planning Assistance Platform for College Students Combining Fuzzy Logic and Deep Learning. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 2025, vol. 29, no. 3, pp. 445–455, DOI: 10.20965/jaciii.2025.p0445.
37. José-García A., Sneyd A., Melro A., et al. C3-IoC: A Career Guidance System for Assessing Student Skills Using Machine Learning and Network Visualisation. *International Journal of Artificial Intelligence in Education*, 2023, vol. 33, no. 4, pp. 1092–1119, DOI: 10.1007/s40593-022-00317-y.

38. Li D., Wang Y., Liao M. Multi-Modal Deep Learning Models in Career Guidance for College Students: Fusing Text, Image, and Behavioral Data. Proceedings of the 8th International Conference on Software Engineering and Information Management (ICSIM 2025), Singapore, ACM, 2025, pp. 226–232, DOI: 10.1145/3725899.3725933.
39. Kumbhar V.R., Maddel M.M., Raut Y. Smart Model for Career Guidance Using Hybrid Deep Learning Technique. 2023 1st International Conference on Innovations in High-Speed Communication and Signal Processing (IHCS), IEEE, 2023, pp. 327–331, DOI: 10.1109/IHCS56702.2023.10127152.
40. Wang Q., Wang D., Chen K., et al. AdaptJobRec: Enhancing Conversational Career Recommendation through an LLM-Powered Agentic System. arXiv preprint arXiv:2508.13423, 2025, DOI: 10.48550/arXiv.2508.13423.
41. Ramesh V., Hema M.S., Shetty R.V., et al. SavvyAI: AI enhanced personalized career guidance system. Proceedings of the 5th IEEE International Conference on Intelligent Technologies (CONIT 2025), Karnataka, India, IEEE, 2025, DOI: 10.1109/CONIT65521.2025.11167621.
42. Kulugh V.E., Aondover K.P., Faki A.S. Artificial intelligence-powered personalised career guidance system. Dutse Journal of Pure and Applied Sciences, 2025, vol. 11, no. 1c, pp. 92–104, DOI: 10.4314/dujopas.v11i1c.11.
43. Shahzada A., Hussain I., Shaheen N., Hussain S.M., Khan T.F., Shehzad M. CAREERLLAMA: An AI-powered personalized career recommendation system with psychometric and skill gap integration. Spectrum of Engineering Sciences, 2025, vol. 3, no. 6, DOI: 10.5281/zenodo.15674001.
44. Arya K., Deshmukh V., Tamboli S., et al. SkillSet Sherpa: Career counseling with large language models. International Conference on ICT for Sustainable Development, Singapore, Springer Nature Singapore, 2024, pp. 269–279, DOI: 10.1007/978-981-97-9523-9\_23.

*Иващенко Анастасия Олеговна. Научный сотрудник лаборатории прикладного искусственного интеллекта Санкт-Петербургского Федерального исследовательского центра Российской академии наук. Область научных интересов: Data Science, машинное обучение, технологии обработки знаний, профессиональная ориентация, выбор карьеры, анализ цифровых следов, анализ социальных сетей. AuthorID: 1024011, SPIN: 1767-6405, ORCID: 0000-0002-9811-5476, aok@dscs.pro. 199178, Россия, Санкт-Петербург, 14-я линия В.О., д. 39.*

---

UDC 004.89

DOI:10.25729/ESI.2026.42.2.013

## **Intelligent career guidance models: structural analysis and formal problem formulation**

**Anastasiia O. Ivashchenko**

St. Petersburg Federal Research Center of the Russian Academy of Sciences,  
Russia, St. Petersburg, *aok@dscs.pro*

**Abstract.** This article systematizes modern methods of intelligent career guidance and proposes a unified computational model of recommendations that integrates psychometric data, digital footprints, academic indicators, and textual descriptions of professions. The relevance of the study is driven by the transition from isolated diagnostic techniques to comprehensive, data-driven career support systems capable of accounting for heterogeneous user information and the dynamics of professional trajectories. The aim of the work is to enhance the quality and interpretability of career guidance recommendations by analyzing existing approaches and developing a mathematically rigorous model that integrates three key tasks: reconstructing professional interests, multimodal matching between user preferences and occupational profiles, and ranking possible career trajectories. The article presents an overview of studies published between 2020 and 2025, demonstrating improvements in the accuracy and robustness of career guidance methods achieved through ensemble algorithms, multimodal deep learning architectures, and LLM-based conversational systems. The analysis shows that combining psychometric profiles, digital activity, and textual descriptions of professions substantially increases the quality of recommendations in both interest reconstruction and career selection tasks. The scientific novelty of the work lies in proposing a unified theoretical and computational framework for intelligent career guidance, which provides a common mathematical structure for diverse existing approaches and enables viewing them as special cases of a general model. The proposed framework includes a formal representation of user and profession data, a RIASEC

profile reconstruction function, a parameterized multimodal matching mechanism, and a joint optimization objective that simultaneously trains all components. This formalization establishes a foundation for developing interpretable, reproducible, and scalable career guidance systems.

**Keywords:** career guidance, career choice, artificial intelligence, Holland Codes (RIASEC), multimodal data, digital footprint, intelligent systems, psychometrics

**Acknowledgements:** This work was carried out within the framework of the project under the state assignment of SPC RAS no. FFZF-2025-0006.

## References

1. Ivakina M.V. Sravnitel'nyj analiz sistem proforientatsionnoj raboty v Rossii i za rubezhom [Comparative analysis of career guidance systems in Russia and abroad]. *Pedagogicheskoye obrazovaniye v Rossii* [Pedagogical education in Russia], 2022, no. 3, pp. 85–94.
2. Gorbunova N.V. Ot vybora professii k professional'noj kar'ere i uspehu v zhizni [From choosing a profession to a professional career and success in life]. *Gumanitarnyye nauki* [Humanities], 2016, no. 2(34), pp. 28–33.
3. Prjazhnikova E.Ju., Prjazhnikov N.S. Proforientatsija: ucheb. posobie dlja stud. vyssh. ucheb. zavedenij [Career guidance: textbook for university students]. Moscow, Akademiya [Academy] Publ., 2006, 496 p.
4. Bendjukov M.A., Solomin I.L. Stupeni kar'ery: azbuka proforientatsii [Career steps: the alphabet of career guidance]. St. Petersburg, Rech', 2006, 240 p.
5. Holland J.L. *Making Vocational Choices: A Theory of Vocational Personalities and Work Environments*. Englewood Cliffs (NJ), Prentice-Hall, 1985.
6. Vorob'ev A.N., Senin I.G., Chirkov V.I. Oprosnik professional'nyh predpochtenij: rukovodstvo [Vocational preference inventory: manual]. 3rd ed., Moscow, Kogito-Centr, 2001, 20 p.
7. Batista J.S., Gondim S.M.G. Personality and Person–Work Environment Fit: A Study Based on the RIASEC Model, *International Journal of Environmental Research and Public Health*, 2022, vol. 20, no. 1, p. 719, DOI: 10.3390/ijerph20010719.
8. Chu C., Hoff K.A., Liu Z., et al. Interest Fit Beyond the RIASEC: The Comprehensive Assessment of Basic Interests – O\*NET (CABIN-NET). *Journal of Career Assessment*, 2025, article 10690727251322520, DOI: 10.1177/10690727251322520.
9. Roemer L., Lewis P., Rounds J. The German O\*NET Interest Profiler Short Form. *Psychological Test Adaptation and Development*, 2023, vol. 4, no. 1, pp. 156–167, DOI: 10.1027/2698-1866/a000048.
10. Englert B. The Incongruity of Misfit: A Systematic Literature Review and Future Research Agenda. *Human Relations*, 2024, vol. 77, no. 9, pp. 1306–1332, DOI: 10.1177/00187267231187751.
11. Sun Y. What Is This Thing Called Misfit? A Systematic Review into How Employee Misfit Has Been Defined and Researched. *Management Review Quarterly*, 2024, pp. 1–64, DOI: 10.1007/s11301-024-00461-w.
12. Ertl B., Hartmann F.G., Wunderlich A. Impact of Interest Congruence on Study Outcomes, *Frontiers in Psychology*, 2022, vol. 13, article 816620, DOI: 10.3389/fpsyg.2022.816620.
13. Marengo D., Settanni M. Examining the Postdictive Validity of Self-Report Big Five Personality Traits with Objective Recordings of Online Behaviors: A Ten-Year Retrospective Study Using Facebook Page Likes. *Heliyon*, 2024, vol. 10, no. 12, DOI: 10.1016/j.heliyon.2024.e32746.
14. Oliseenko V.D., Abramov M.V. Predicting the Results of the 16-Factor R. Cattell Test Based on the Analysis of Text Posts of Social Network Users, *Scientific and Technical Journal of Information Technologies. Mechanics and Optics*, 2023, vol. 148, no. 2, pp. 279–288, DOI: 10.17586/2226-1494-2023-23-2-279-288.
15. Samoilova L., Danilovskii V.M. Prognozirovanie lichnostnyh harakteristik MBTI s ispol'zovaniem rekurrentnoj nejronnoj seti LSTM i tekstovyh dannyh social'nyh setej [Predicting MBTI personality characteristics using an LSTM recurrent neural network and social-media text data]. *Vestnik nauki* [Bulletin of science], 2024, vol. 4, no. 6(75), pp. 1176–1184.
16. Khan A., Maneria H., Kumar A., et al. A Comprehensive Examination of Machine Learning Models in Predicting 16 Personality Traits. *Doctoral Symposium on Computational Intelligence*, Singapore, Springer Nature, 2024, pp. 1–13, DOI: 10.1007/978-981-97-6726-7\_1.
17. Goyal C., Kemni D., Pandey M. An Evaluation of Machine Learning Techniques for Personality Classification Using the Myers–Briggs Assessment. *International Conference on Innovative Computing and Communication*, Singapore, Springer Nature, 2024, pp. 555–570, DOI: 10.1007/978-981-97-3591-4\_42.
18. Yang Q., Farseev A., Nikolenko S., Filchenkov A. Do We Behave Differently on Twitter and Facebook: Multi-View Social Network User Personality Profiling for Content Recommendation. *Frontiers in Big Data*, 2022, vol. 5, article 931206, DOI: 10.3389/fdata.2022.931206.
19. Khlobystova A.O., Abramov M.V., Stoliarova V.F. Issledovanie tendentsij vzaimosvjazi mezhdru proforientatsionnymi predpochtenijami pol'zovatelej i ih tsifrovymi sledami v sotsial'noj seti [Investigation of

- trends in the relationship between users' career preferences and their digital traces in a social network]. *Nauchno-tekhnicheskij vestnik informatsionnykh tekhnologiy, mekhaniki i optiki* [Scientific and technical journal of information technologies, mechanics and optics], 2023, vol. 23, no. 3, pp. 564–574, DOI: 10.17586/2226-1494-2023-23-3-564-574.
20. Khlobystova A.O., Abramov M.V., Stoliarova V.F. Characterization of the Person's Leading Interests in Terms of RIASEC Scores, *International Conference on Intelligent Information Technologies for Industry*. Cham, Springer Nature Switzerland, 2023, pp. 281–290, DOI: 10.1007/978-3-031-43789-2\_26.
  21. Malakhov V.V., Smyshlyaeva L.G., Melentyeva A.N., Okorokov A.O. Ispol'zovanie bol'shih dannyh v praktikah proforientatsii shkol'nikov na meditsinskuyu professiju [The use of big data in practices of school career guidance towards the medical profession]. *Perspektivy nauki i obrazovaniya* [Perspectives of science and education], 2023, no. 6(66), pp. 516–531, DOI: 10.32744/pse.2023.6.30.
  22. Malakhov V.V. Osobennosti ispol'zovaniya tekhnologij bol'shih dannyh v praktikah proforientatsii shkol'nikov na pedagogicheskuyu dejatel'nost' [Features of using big-data technologies in practices of school career guidance towards teaching]. *Nauchno-pedagogicheskoye obozreniye* [Scientific and pedagogical review], 2025, no. 1(59), pp. 56–65, DOI: 10.23951/2307-6127-2025-1-56-65.
  23. Erbay H., Yurttakal A.H., Dağistanlı Ö., et al. Advising Career Choice Through Tweeter Data. *Multimedia Tools and Applications*, 2024, pp. 1–17, DOI: 10.1007/s11042-024-20440-3.
  24. Kiselev P., Kiselev B., Matsuta V., et al. Career Guidance Based on Machine Learning: Social Networks in Professional Identity Construction. *Procedia Computer Science*, 2020, vol. 169, pp. 158–163, DOI: 10.1016/j.procs.2020.02.128.
  25. Zabokritskaya L.D., Oreshkina T.A., Obabkov I.N., Chepurov E.G. Wizard: intellektual'naja sistema proforientatsii dlja abiturientov na osnove mashinnogo obuchenija [Wizard: An intelligent career-guidance system for applicants based on machine learning]. *Vestnik Tomskogo gosudarstvennogo universiteta* [Bulletin of Tomsk state university], 2022, no. 485, pp. 217–225.
  26. Chekalev A., Khlobystova A., Abramov M. Community Theme Analyser: Predicting Career Guidance in Online Social Networks. *Proceedings of the Eighth International Scientific Conference "Intelligent Information Technologies for Industry" (IITI'24)*, vol. 2, IITI 2024, pp. 153–162, DOI: 10.1007/978-3-031-77411-9\_14.
  27. Panthee S., Rajkarnikar S., Begum R. Career Guidance System Using Machine Learning. *Journal of Advanced College of Engineering and Management*, 2023, vol. 8, no. 2, pp. 10–19, DOI: 10.3126/jacem.v8i2.55947.
  28. Kamal A., Naushad B., Rafiq H., et al. Smart Career Guidance System. *2021 4th International Conference on Computing & Information Sciences (ICCIS)*, IEEE, 2021, pp. 1–7, DOI: 10.1109/ICCIS54243.2021.9676408.
  29. Reddy K., Reddy M.A., Kaur V., et al. Career Guidance System Using Ensemble Learning. *Proceedings of the Advancement in Electronics & Communication Engineering*, 2022, pp. 33–39, DOI: 10.2139/ssrn.4157249.
  30. Padma E., Sowdharshini P., Shanmugapriya P., et al. Career Guidance System for Students Using Machine Learning, *Challenges in Information, Communication and Computing Technology*. CRC Press, 2025, pp. 666–671, DOI: 10.1201/9781003559092-115.
  31. Yang T.C., Chang C.Y. Using Institutional Data and Messages on Social Media to Predict the Career Decisions of University Students: A Data-Driven Approach. *Education and Information Technologies*, 2023, vol. 28, no. 1, pp. 1117–1139, DOI: 10.1007/s10639-022-11185-3.
  32. Gülten H., Baraçlı H. A Machine Learning-Based Forecast Model for Career Planning in Human Resource Management: A Case Study of the Turkish Post Corporation. *Applied Sciences*, 2024, vol. 14, no. 15, article 6679, DOI: 10.3390/app14156679.
  33. Song Q.C., Shin H.J., Tang C., et al. Investigating Machine Learning's Capacity to Enhance the Prediction of Career Choices. *Personnel Psychology*, 2022, vol. 77, no. 2, pp. 295–319, DOI: 10.1111/peps.12529.
  34. Sergushicheva A.P., Davydova E.N. Postroenie komp'yuternoj sistemy proforientatsii vypusnikov srednih obrazovatel'nyh zavedenij na baze geneticheskogo algoritma [Building a computer career-guidance system for secondary-school graduates based on a genetic algorithm]. *Otkrytoye obrazovaniye* [Open education], 2020, no. 3, DOI: 10.21686/1818-4243-2020-3-33-43.
  35. Tarasova A.S., Komarova E.P. Proektirovanie rekomendatel'noj sistemy proforientatsii shkol'nikov sredstvami mashinnogo obuchenija [Designing a career-guidance recommender system for school students using machine learning]. *Gumanitarnyye issledovaniya. Pedagogika i psikhologiya* [Humanities research. Pedagogy and psychology], 2024, no. 17, pp. 7-14.
  36. Cheng Y. Development of a Career Planning Assistance Platform for College Students Combining Fuzzy Logic and Deep Learning. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 2025, vol. 29, no. 3, pp. 445–455, DOI: 10.20965/jaciii.2025.p0445.

37. José-García A., Sneyd A., Melro A., et al. C3-IoC: A Career Guidance System for Assessing Student Skills Using Machine Learning and Network Visualisation. *International Journal of Artificial Intelligence in Education*, 2023, vol. 33, no. 4, pp. 1092–1119, DOI: 10.1007/s40593-022-00317-y.
38. Li D., Wang Y., Liao M. Multi-Modal Deep Learning Models in Career Guidance for College Students: Fusing Text, Image, and Behavioral Data. *Proceedings of the 8th International Conference on Software Engineering and Information Management (ICSIM 2025)*, Singapore, ACM, 2025, pp. 226–232, DOI: 10.1145/3725899.3725933.
39. Kumbhar V.R., Maddel M.M., Raut Y. Smart Model for Career Guidance Using Hybrid Deep Learning Technique. *2023 1st International Conference on Innovations in High-Speed Communication and Signal Processing (IHCSP)*, IEEE, 2023, pp. 327–331, DOI: 10.1109/IHCSP56702.2023.10127152.
40. Wang Q., Wang D., Chen K., et al. AdaptJobRec: Enhancing Conversational Career Recommendation through an LLM-Powered Agentic System. *arXiv preprint arXiv:2508.13423*, 2025, DOI: 10.48550/arXiv.2508.13423.
41. Ramesh V., Hema M.S., Shetty R.V., et al. SavvyAI: AI enhanced personalized career guidance system. *Proceedings of the 5th IEEE International Conference on Intelligent Technologies (CONIT 2025)*, Karnataka, India, IEEE, 2025, DOI: 10.1109/CONIT65521.2025.11167621.
42. Kulugh V.E., Aondover K.P., Faki A.S. Artificial intelligence-powered personalised career guidance system. *Dutse Journal of Pure and Applied Sciences*, 2025, vol. 11, no. 1c, pp. 92–104, DOI: 10.4314/dujopas.v11i1c.11.
43. Shahzada A., Hussain I., Shaheen N., Hussain S.M., Khan T.F., Shehzad M. CAREERLLAMA: An AI-powered personalized career recommendation system with psychometric and skill gap integration. *Spectrum of Engineering Sciences*, 2025, vol. 3, no. 6, DOI: 10.5281/zenodo.15674001.
44. Arya K., Deshmukh V., Tamboli S., et al. SkillSet Sherpa: Career counseling with large language models. *International Conference on ICT for Sustainable Development*, Singapore, Springer Nature Singapore, 2024, pp. 269–279, DOI: 10.1007/978-981-97-9523-9\_23.

**Ivashchenko Anastasiia Olegovna.** *Researcher at the Applied Artificial Intelligence Laboratory of the St. Petersburg Federal Research Centre of the Russian Academy of Sciences. Areas of scientific interest: Data Science, machine learning, knowledge processing technologies, professional orientation, career choice, digital footprint analysis, social network analysis. AuthorID: 1024011, SPIN: 1767-6405, ORCID: 0000-0002-9811-5476, aok@dscs.pro. 199178, Russia, Saint Petersburg, 14th Line V.O., 39.*

*Статья поступила в редакцию 04.12.2025; одобрена после рецензирования 16.01.2026; принята к публикации 21.05.2026.*

*The article was submitted 12/04/2025; approved after reviewing 01/16/2026; accepted for publication 05/21/2026.*

## Программные системы и комплексы

УДК 517.977.58

DOI:10.25729/ESI.2026.42.2.014

### Специализированные алгоритмы и программные средства оптимизации нелинейных управляемых динамических систем

Зароднюк Татьяна Сергеевна

Институт динамики систем и теории управления им. В.М. Матросова СО РАН,  
Россия, Иркутск, *tz@icc.ru*

**Аннотация.** Разработанные алгоритмы решения нелинейных задач оптимального управления и аппроксимации невыпуклых множеств достижимости легли в основу реализованных специализированных программных средств, ориентированных на исследование нелинейных управляемых динамических систем. Подобные системы возникают в различных научно-технических и промышленных областях, характеризуются высокой степенью сложности (нелинейными динамическими системами и невыпуклыми целевыми функционалами), поэтому для их эффективного решения требуется использование алгоритмов, позволяющих учитывать специфику задач рассматриваемого класса. В работе предложены соответствующие вычислительные технологии, опирающиеся как на использование классических подходов, основанных на последовательной дискретизации непрерывных задач и применении принципа максимума Понтрягина, так и опирающиеся на использование специфических особенностей управляемых динамических систем – свойства линейной связности множества достижимости и свойства скрытой выпуклости множества допустимых скоростей управляемых динамических систем. Методики предоптимизационного анализа (оценки степени выпуклости целевых функционалов и построения границы множества достижимости) также реализованы в виде программ, позволяющих на старте оценить вычислительную сложность прикладных задач невыпуклой оптимизации и подобрать эффективные численные методы для ее решения.

Приводятся описания математической, программной и технологической постановок исследуемых невыпуклых задач оптимального управления. Представлена схема методологии синтеза многометодных нелокальных алгоритмов для оптимизации управляемых динамических систем. Описаны этапы формирования вычислительной схемы и особенности выбора значений алгоритмических параметров.

Для тестирования программных реализаций алгоритмов невыпуклой оптимизации с целью исследования их предельных свойств и поиска эффективных модификаций используется разработанная тестовая коллекция нелинейных задач оптимального управления. Коллекция включает как опубликованные задачи с известными решениями, так и сгенерированные с использованием предложенной методики генерации тестов. Разработанные алгоритмы и соответствующее программное обеспечение применялось при решении практических задач из различных научно-технических областей: динамики полета и космонавигации, квантовой физики и вычислительной химии, синтеза композитных конструкций, экономики, медицины, технической экологии и других областей.

**Ключевые слова:** алгоритмы невыпуклой оптимизации, задачи оптимального управления, нелинейные управляемые динамические системы

**Цитирование:** Зароднюк Т.С. Специализированные алгоритмы и программные средства оптимизации нелинейных управляемых динамических систем / Т.С. Зароднюк // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 177-189. – DOI:10.25729/ESI.2026.42.2.014.

**Введение.** Область исследования прикладных управляемых динамических систем развивается очень активно, подобные задачи возникают в различных научно-технических областях: космонавигации и динамики полета, квантовой физики, технической экологии и медицины, синтеза композитных конструкций, экономике, географии, сейсмологии и многих других. Необходимо разрабатывать соответствующие вычислительные технологии решения подобных невыпуклых задач оптимального управления (ЗОУ). В работе предложено специализированное программное обеспечение, ориентированное на исследование практических задач траекторной оптимизации и представлены результаты его применения при решении задач из тестовой коллекции.

Реализованные программные средства невыпуклой оптимизации позволяют проводить численное исследование управляемых динамических систем, получать овыпукление множества допустимых скоростей и аппроксимировать множество достижимости (МД). Методики предоптимизационного анализа ориентированы на получение оценок степени выпуклости функционала и построение границы множества достижимости управляемых динамических систем. Арсенал реализованных средств невыпуклой оптимизации включает – моноволновой алгоритм построения границы множества достижимости [1] и алгоритм оценки степени выпуклости целевого функционала [2]; алгоритмы аппроксимации множества достижимости (криволинейного поиска, туннельного типа, и овыпукления множества скоростей и методы покрытий МД [3]), а также траекторной оптимизации (методы, основанные на принципе максимума Понтрягина и последовательной дискретизации [4]). Эффективность реализованных алгоритмов зависит от выбора значений алгоритмических параметров, который можно осуществить путем проведения многовариантного тестирования.

Для формирования программной постановки невыпуклой задачи оптимального управления для реализованных алгоритмов используется последовательность процедур, в которых на языке С описаны – целевой оптимизируемый функционал, система дифференциальных уравнений, ограничения на интервал ее функционирования, а также на управления и фазовые координаты. В результате численного решения получают наборы табличных данных – значения траекторий и управлений на временной сетке с заданным шагом дискретизации. Визуализация достигнутых результатов может быть выполнена разными способами, например, с использованием языка программирования Python (стандартная графическая библиотека Matplotlib) или графических редакторов Grapher и Surfer (Golden Software), позволяющих строить как двумерные графики полученных результатов, так и поверхности в трехмерном пространстве.

Традиционно выделяют несколько вариантов представления постановки задачи для программных реализаций алгоритмов невыпуклой оптимизации [5]: математическая, программная и технологическая постановки задачи.

*Математическая постановка* подразумевает полное представление используемой для описания динамического процесса математической модели, которое включает соответствующую систему дифференциальных уравнений; ограничения на фазовые координаты в начальный момент времени и на управления на всем интервале времени функционирования системы; а также минимизируемый функционал, позволяющий оценить качество управляющего воздействия с целью выбора наилучшего.

*Программная постановка задачи* – постановка, записанная с помощью команд выбранного языка программирования (в данном случае языка С), основанная на интерпретации математической постановки для реализованных алгоритмов невыпуклой оптимизации, и включающая технологическую постановку.

*Технологическая постановка задачи* – это описание конкретной задачи оптимального управления, включающее способ дискретизации исходной управляемой динамической системы, задание значений параметров алгоритмов, входящих в состав сформированной многометодной схемы, а также номер и название задачи, необходимые для дальнейшей обработки файлов с результатами полученных численно решений.

**1. Описание исследуемых управляемых динамических процессов.** Математические модели, позволяющие проводить исследования управляемых динамических процессов, могут быть описаны системами обыкновенных дифференциальных уравнении с заданными ограничениями:

$$\dot{x} = f(x(t), u(t), t), \quad x(t_0) = x^0, \quad t \in T = [t_0, t_1], \quad (1)$$

$$u \in U = \{u \in R^m: \underline{u}_i \leq u_i \leq \bar{u}_i, i = \overline{1, m}\}, \quad (2)$$

$$I[x, u] = \phi(x(t_1)) \rightarrow \min. \quad (3)$$

Эта постановка является эталонной, при наличии ограничений, которые в ней не представлены, можно путем стандартных редукций привести более сложные задачи к эталонному виду (1)–(3). Например, критерий качества допустимых управляющих воздействий может быть представлен в виде функционала интегрального типа:

$$I[x, u] = \int_{t_0}^{t_1} g_0(x(t), u(t), t) dt \rightarrow \min.$$

Достаточно ввести дополнительную фазовую координату  $\dot{x}_{n+1}(t) = g_0(x(t), u(t), t)$ ,  $x_{n+1}(t_0) = x^0$  для представления целевого функционала в линейном терминальном виде:  $I[x, u] = x_{n+1}(t_1) \rightarrow \min$ . Задача аппроксимации множества достижимости заключается в нахождении (аппроксимации) множества конечных векторов  $x(t_1)$  всех траекторий, которые соответствуют всем возможным допустимым управлениям – управлениям, удовлетворяющим заданным геометрическим ограничениям (2).

**1.1. Программная постановка задачи** заключается в описании компонентов задачи оптимального управления на программном языке и включает, помимо математических формулировок, ряд технологических блоков. Здесь же задаются значения алгоритмических параметров, в случае отсутствия их явно заданных значений – выбираются те, которые предусмотрены по умолчанию. Программная постановка задачи для реализованных средств оптимизации управляемых динамических систем представляет собой описание задачи на языке программирования С. Пользователю при формировании описания конкретной задачи необходимо представить следующие компоненты:

- Процедура 01 позволяет зафиксировать размерности задачи – число фазовых переменных и управляющих воздействий (как функций, так и управлений–параметров), временной интервал с выбранным шагом дискретизации;
- Процедура 02 включает задание ограничений на управление и фазовый вектор в начальный момент времени;
- Процедура 03 позволяет описать нелинейную систему дифференциальных уравнений, представляющую исследуемый процесс.
- Процедура 04 включает задание вида целевого функционала, оценивающего качество управляющих воздействий.

Набор алгоритмических параметров зависит от используемых методов решения задачи и может существенно отличаться для разных вариантов вычислительных схем.

**1.2. Технологическая постановка задачи** основана на детальном описании всех компонентов математической постановки и требуемых для ее решения составляющих – как задаваемых пользователем, так и используемых из заранее установленных для организации автоматических вычислений:

1. Исходные размерности задачи (число фазовых переменных, число управлений–параметров, число управлений–функций, число постановочных параметров для метода штрафных функций, когда это необходимо).
2. Система дифференциальных уравнений с управлениями–функциями и управлениями–параметрами.
3. Интервал времени функционирования системы, характеризующий исследуемый управляемый динамический процесс.
4. Ограничения на фазовые координаты в момент времени  $t_0$ .
5. Геометрические ограничения на управления.
6. Параметризация модели и значения постановочных параметров.

7. Дискретизация исходной задачи на начальном этапе, стартовый метод интегрирования и максимальные размеры сетки дискретизации.
8. Начальные приближения к управляющим воздействиям.
9. Режимы вывода итоговых результатов – протоколов вычислительного процесса, табличных данных, характеризующих как наилучшие траектории системы и управления, так и позволяющих построить аппроксимацию множеств достижимости.

Приведем пример программной постановки задачи на языке С, включающей перечисленные выше компоненты для двумерной тестовой задачи (табл. 1):

**Таблица 1.** Программная постановка невыпуклой тестовой ЗОУ


<code>// Test_001</code>	
<code>// Процедура 01 (выбор методов и значений алгоритмических параметров)</code>	
<code>void init_dimension(void) { // PARAMETERS   n = 2;   ru = 1;   rv = 0;   t0 = 0.0;   t1 = 7.0;   nu = 101;    met_glob = 3;   met_gener = 1;   u1_kp = 3;   met_integ = 2;   met_lok = 1;   eps_int = 1e-8;   delta_fi0 = 1e-6;   gs1_nstoxa = 30000;   iprint = 1; } // init_dimension</code>	<code>// число фазовых переменных; // количество управляющих функций; // число управляющих параметров; // начальный момент времени; // конечный момент времени; // количество узлов дискретизации интервала времени;  // метод нелокальной оптимизации; // алгоритм генерации управлений (функции рейного типа); // количество точек переключения // метод интегрирования; // метода локального поиска; // локальная точность интегрирования; // точность по функционалу; // число точек стохастической аппроксимации МД; // параметр, отвечающий за детализацию выдачи численных результатов в текстовые файлы;</code>
<code>// Процедура 02 (задание значений фазового вектора в начальный момент времени и ограничений на управляющие воздействия)</code>	
<code>void init_data(void) { // MODEL   x0[1] = 5.0;   x0[2] = 0.0;   u1[1] = -1.0;   ug[1] = 1.0; } // initial_data</code>	<code>// начальный фазовый вектор // границы области допустимых управлений (нижняя и верхняя)</code>
<code>// Процедура 03 (формулировка правых частей системы дифференциальных уравнений)</code>	
<code>void fp(double* x, double u, double t, double* dxdt) { // ODE SYSTEM   dxdt[1] = x[2];   dxdt[2] = u[1] - x[1] + x[1] * x[1] * x[1] / 6.0 -           x[1] * x[1] * x[1] * x[1] * x[1] / 120.0; } // fp</code>	
<code>// Процедура 04 (задание терминального целевого функционала)</code>	
<code>double fi(double* xt1) { // OBJ_FUNC   return (xt1[1] + 1.0) * (xt1[1] + 1.0) + (xt1[2] - 9.5) * (xt1[2] - 9.5); } // fi</code>	

## 2. Схема методологии синтеза многометодных нелокальных алгоритмов для ЗОУ.

Помимо требований к математической постановке исследуемой задачи (дифференцируемость входящих в постановку функций, учет ограничений на управление и фазовые координаты), для успешного применения разработанных алгоритмов необходимо организовать

продуктивный диалог между специалистом в предметной области – постановщиком задачи, и специалистом по разработке и использованию методов невыпуклой оптимизации. На верхнем уровне схемы присутствует также эксперт–постановщик математической модели, описывающей исследуемый динамический процесс. В некоторых случаях при решении прикладных задач таким экспертом может являться отдельный специалист, принимающий участие в совместных исследованиях или опубликовавший модель, которую можно использовать при изучении динамических процессов, но чаще эти функции берет на себя эксперт из предметной области или вычислитель, обладающий опытом решения множества практических задач из различных научно-технических областей.

**2.1. Этапы формирования вычислительной схемы исследования управляемых динамических систем.** Готовые математические модели используются в редких случаях, как правило, на старте формализации описания исследуемого процесса. У специалиста в предметной области есть накопленная база данных о вызывающих интерес экспертных факторах, которые необходимо проанализировать, использовать для формирования обобщающих выводов и прогнозов, или известные закономерности, хорошо изученные модели, которые не всегда позволяют детально описывать исследуемый процесс. Поэтому этап формирования математической модели для прикладной динамической задачи является творческим и многошаговым, где важную роль играет продуктивный диалог между экспертами (рис. 1).

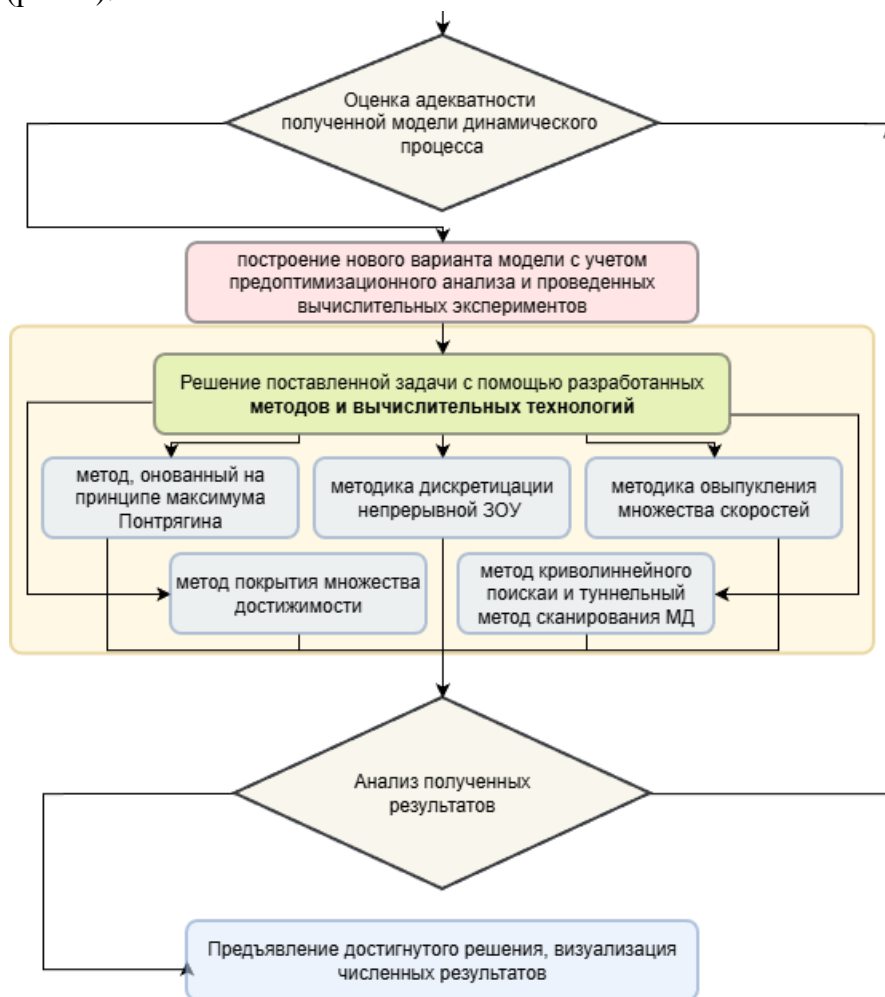


**Рис. 1.** Схема методологии синтеза разработанных алгоритмов невыпуклой оптимизации управляемых динамических систем (начало)

После формирования предварительного варианта модели реализуется ее предоптимизационный анализ:

1. Применение методики оценки степени выпуклости целевого функционала для определения уровня сложности соответствующей задачи траекторной оптимизации.
2. Использование моноволнового метода, позволяющего построить границу множества достижимости за счет формирования семейства управляющих воздействий релейного типа.
3. Поиск значений параметров модели подразумевает решение вспомогательных задач параметрической идентификации для нахождения наилучших значений из заданных интервалов.
4. Проведение вычислительных экспериментов по подбору штрафных коэффициентов при наличии в модели дополнительных фазовых и терминальных ограничений.

По результатам предоптимизационного анализа модели осуществляется оценка полученных результатов экспертами из предметной области и специалистами по методам невыпуклой оптимизации, как в направлении оценки степени адекватности представления исследуемого процесса, так и с точки зрения возникающих вычислительных сложностей с целью выбора наиболее эффективных методов и вычислительных технологий, позволяющих их преодолевать (рис. 2).



**Рис. 2.** Схема методологии синтеза разработанных алгоритмов невыпуклой оптимизации управляемых динамических систем (продолжение)

По результатам анализа осуществляется корректировка модели при необходимости и формирование рекомендованных для ее эффективного исследования *методов невыпуклой оптимизации управляемых динамических систем*.

1. Методы сканирования множества достижимости (семейство методов криволинейного поиска) путем построения вариаций управления с целью поиска минимума целевого функционала вдоль соответствующих кривых, покрывающих множество достижимости.
2. Методы туннельного типа, позволяющие за счет чередования стадий минимизации и туннельного выхода из уже найденных экстремумов, достигать решения в задачах невыпуклой траекторной оптимизации.
3. Алгоритм, основанный на принципе максимума Понтрягина, позволяющий за счет использования Гамильтониана и сопряженной системы дифференциальных уравнений получать управляющие воздействия в исходной ЗОУ.
4. Методики овыпукления множества допустимых скоростей управляемых динамических систем, позволяющие получить задачу с лучшими свойствами за счет формирования расширенной ЗОУ.
5. Метод покрытий, ориентированный на покрытие МД шарами, радиус которых зависит от оценки константы Липшида (увеличивается при удалении от экстремального значения целевого функционала).
6. Методика дискретизации, ориентированная на сведении исходной непрерывной задачи к последовательности конечномерных, с дальнейшим применением нелокального метода парабол для поиска областей, содержащих экстремумы целевого функционала.
7. Интегрирование системы дифференциальных уравнений в простых случаях реализуется с помощью стандартного метода Эйлера, а в более сложных задачах большой размерности используется метод Дормана–Принса, позволяющий подбирать шаг интегрирования и достигать более точных результатов [6].
8. Вспомогательный алгоритм локального поиска – алгоритм приведенного градиента, используется на завершающих этапах численного решения для уточнения результата, полученного на предыдущих этапах.
9. Алгоритмы генерации случайных управляющих воздействий, в которых заложена гипотеза о структуре управлений (функции релейного типа с заданным числом точек переключения, кусочно-линейные управляющие функции и сплайн-функции с обязательным проецированием на допустимое множество).

Решение соответствующей задачи траекторной оптимизации оценивается экспертами, и при необходимости также вносятся изменения в математическую модель. При исследовании прикладных динамических задач этот процесс может повторяться многократно и быть ориентирован на усложнение исходной модели для более точного описания динамического процесса и достижения требуемой точности получаемых решений.

**2.2. Задание значений алгоритмических параметров.** Проблема выбора наиболее подходящих значений алгоритмических параметров решается, как правило, в результате вычислительных экспериментов для каждой конкретной постановки задачи. Тем не менее могут быть сформированы рекомендации по их выбору по результатам многовариантного глубокого тестирования на коллекции невыпуклых тестовых задач оптимального управления.

1. Алгоритмы генерации стартовых управляющих воздействий в виде релейных функций зависят от алгоритмического параметра – число точек переключения, которое может быть фиксированным или выбираться из некоторого интервала. В результате тестирования установлено, что в большинстве случаев результативнее всего использовать управления с тремя точками переключения –  $u_{кр} = 3$  (табл. 1), но на этапе предоптимизационного анализа для конкретной задачи могут быть сформированы другие рекомендации. Для релейных функций со случайным числом точек переключения стандартным выбрано следующее значение:  $u_{кр} = 5$ .

2. Алгоритмы решения вспомогательной задачи Коши зависят от заданной точности интегрирования (стандартное значение равно  $10^{-8}$ ). Результативность и длительность работы алгоритмов интегрирования также зависит от максимального числа шагов, допустимого на каждом интервале дискретизации (значение этого параметра в стандартном варианте выбирается, например, равным 200 000).
3. Методика последовательной дискретизации опирается на выбор числа узлов сетки дискретизации, на первом этапе формируется поиск приближения к решению на сетке из 5 узлов, на втором – уточнение на более мелкой сетке, например, из 350 узлов.
4. Алгоритмы вспомогательного локального поиска зависят от выбора требуемой точности по функционалу, соответствующее значение может быть равным  $10^{-6}$  (табл. 1).

Выбор значений алгоритмических параметров может оказывать существенное влияние на результативность используемых вычислительных технологий. Поэтому при решении прикладных задач оптимального управления необходимо провести серию вычислительных экспериментов с целью нахождения значений параметров алгоритмов, при которых они наиболее эффективны при решении задач рассматриваемого типа и позволяют учитывать их особенности.

### **3. Тестирование программных реализаций алгоритмов невыпуклой оптимизации.**

Необходимо проводить сравнение новых разрабатываемых подходов с существующими в области оптимизации динамических систем методами, устранять возможные ошибки их программной реализации, исследовать свойства алгоритмов и выделять классы задач, для которых они наиболее эффективны. Тестирование алгоритмов и вычислительных технологий является основным методом экспериментальной оценки их эффективности, который традиционно опирается на использование коллекций тестов. Существуют хорошо известные тестовые коллекции задач математического программирования, авторами которых являются – К. Шитковский, В. Хок, К. Флоудас, П. Пардалос., Д. Мор и другие (см., например, [7, 8]). В области оптимизации управляемых динамических системы результаты не столь многочисленны (см., например, [9]). Проблема конструирования многоэкстремальных тестовых задач оптимального управления, позволяющих проводить сравнение и оценку эффективности методов невыпуклой оптимизации и соответствующих вычислительных технологий, продолжает оставаться актуальной.

**3.1. Методики генерации тестов.** Для включения в коллекцию тестов, построенных с учетом целенаправленного формирования характерных особенностей для задач невыпуклой оптимизации, разработана методика генерации тестов. Предложенная методика ориентирована на моделирование вычислительных трудностей для алгоритмов оптимизации нелинейных управляемых динамических систем и позволяет проводить сравнение и исследование свойств их программных реализаций, включает несколько взаимосвязанных этапов.

*На первом этапе* формируется система дифференциальных уравнений с непрерывными правыми частями. Построение системы основывается по одному из выбранных путей:

- *вариант 1* – использование описания известной механической системы с дальнейшим добавлением модификаций, таких, как, например, удлинение интервала времени, использование разных начальных приближений и ограничений на управления;
- *вариант 2* – построение простой системы путем введения двух вспомогательных управляющих воздействий в случае использования известной многоэкстремальной функции;

– вариант 3 – формирование невыпуклого МД (путем использования нелинейных зависимостей и тригонометрических функций) с дальнейшим добавлением линейного функционала с целью выбора направления, в котором структура МД наиболее сложная.

На втором этапе выбираются значения фазовых координат в начальной точке и интервал изменения времени (с увеличением которого сложность задачи может существенно возрасти).

На третьем этапе задаются ограничения на управляющие воздействия. В качестве эталонных выбраны геометрические ограничения (параллелепипедного типа), как одни из самых естественных и часто возникающих на практике. Ограничения более сложной структуры можно свести путем редукций и применения метода штрафных функций к стандартному виду. Далее осуществляется построение множества достижимости полученной управляемой динамической системы (рис. 3).

В результате анализа построенного множества достижимости выбирается терминальный функционал с целью получения нескольких экстремальных точек. Если МД выпуклое или при численном решении задачи найден только один экстремум, то выполняется последовательное усложнение теста: а) увеличивается интервал времени, б) редактируется множество допустимых управлений, в) изменяется целевой терминальный функционал.

На последнем этапе осуществляется визуализация полученного решения и оформление сгенерированной задачи. В многоэкстремальных задачах точное решение представлено достаточно редко, поэтому требование наличия известного решения, в соответствии с традиционным подходом в глобальной оптимизации, ослаблено и заменено на следующее – «должно быть представлено лучшее из известных в тестовой задаче решений» (принцип «best known»).

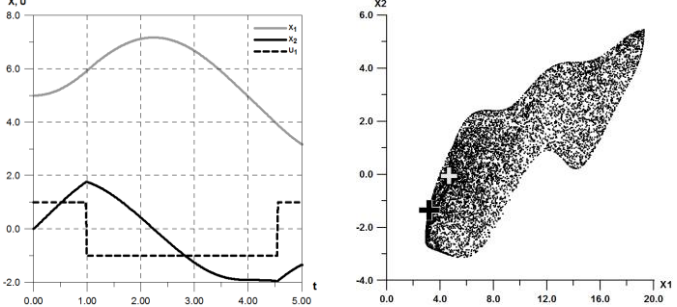
**3.2. Тестовая коллекция невыпуклых задач оптимального управления.** Среди нелинейных задач оптимального управления можно выделить классы задач различной вычислительной сложности, например, с учетом размера области притяжения глобального экстремума. Классическим примером невыпуклой тестовой динамической задачи является задача оптимального управления колебаниями нелинейного маятника (см., например, [5, 6]).



Рис. 3. Методика генерации невыпуклых тестовых ЗОУ

Колебательный процесс описывается нелинейной системой дифференциальных уравнений (табл. 2).

**Таблица 2.** Тестовая ЗОУ колебаниями маятника: постановка, оптимальные траектории, управление и МД

Постановка тестовой задачи <sup>1</sup>	Оптимальные траектории и управления; множество достижимости и экстремальные точки
$\dot{x}_1 = x_2,$ $\dot{x}_2 = u - \sin x_1, t \in [0,5]$ $x_0 = (5, 0), u \in U = [-1, 1]$ $I(u) = x_1^2(t_1) + x_2^2(t_1) \downarrow$	

Минимальные значения функционала достигаются в точках, представленных в таблице 3. Результат получен за 4 сек. процессорного времени, при этом было решено 228 задач Коши.

**Таблица 3.** Результаты численного решения тестовой задачи

№ экстремума	Значение функционала	Координаты точки $(x_1, x_2)$
1	11.90876	(3.17863, -1.34354)
2	21.82921	(4.67180, -0.05900)
Число задач Коши: 228		CPU time: 4 сек.

Сформированная коллекция невыпуклых тестовых задач, включающая как сгенерированные целенаправленно тесты (п.3.1), так и известные ЗОУ (п.3.2), использована для тестирования разработанных специализированных программных средств оптимизации управляемых динамических систем. Реализованные алгоритмы и вычислительные технологии применялись для решения сложных прикладных задач квантовой физики [10], синтеза композитных конструкций, вычислительной химии [11], экономики, технической экологии и медицины [12] и многих других.

**Заключение.** В работе представлена методология синтеза многометодных нелокальных алгоритмов для невыпуклых задач оптимального управления ориентированная на исследование управляемых динамических процессов. Приведено описание математической, программной и технологической постановок задач, для решения которых предназначены разработанные программные средства невыпуклой оптимизации.

Представлена методика генерации многоэкстремальных тестовых задач, включенных в сформированную тестовую коллекцию, ориентированную на исследование свойств программных реализаций алгоритмов оптимизации нелинейных управляемых динамических систем. Приведены примеры тестовых задач и результаты их численного решения. Выделены наиболее трудоемкие в вычислительном плане задачи, наилучшим образом подходящие для сравнения и поиска эффективных модификаций алгоритмов решения нелинейных задач оптимального управления. Разработанные алгоритмы и специализированные программные средства невыпуклой оптимизации использованы при решении задач оптимального управления из различных научно-технических и промышленных областей.

<sup>1</sup> Gornov A.Y., Zarodnyuk T.S., Madzhara T.I., Daneyeva A.V., Veyalko I.A. A collection of test multiextremal optimal control problems. Springer Optimization and Its Applications, 2013, vol. 76, pp. 257–274.

**Благодарности.** Работа выполнена за счет государственного задания в рамках темы «Эволюционные и динамические управляемые системы: теория, численные методы, приложения» (шифр научной темы FWEW-2026-0011, № гос. регистрации 126021217177-7).

#### Список источников

1. Zarodnyuk T., Gornov A. Monowave boundary construction method for the non-convex reachable set of the controlled dynamical system. Springer Proceedings in Mathematics & Statistics: International Conference on Optimization, Simulation and Control (Ulaanbaatar, Mongolia, June 20–22, 2023), 2023, vol. 434, pp. 117–127, DOI: 10.1007/978-3-031-41229-5\_9
2. Gornov A.Yu., Zarodnyuk T.S., Anikin A.S. et al. Extension technology and extrema selections in a stochastic multistart algorithm for optimal control problems. Journal of Global Optimization, 2020, vol. 76, no. 3, pp. 533–543, DOI: 10.1007/s10898-019-00821-x
3. Горнов А.Ю. Метод случайных покрытий для задачи оптимального управления / А.Ю. Горнов, Т.С. Зароднюк // Вычислительные технологии. 2012. – Т. 17. – №2. – С. 31–42.
4. Зароднюк Т.С. Алгоритм численного решения многоэкстремальных задач оптимального управления с параллелепипедными ограничениями / Т.С. Зароднюк // Вычислительные технологии. 2013. – Т. 18. – №2. – С. 46–54.
5. Горнов А.Ю. Вычислительные технологии решения задач оптимального управления / А.Ю. Горнов. – Новосибирск: Наука, 2009. – 279 с.
6. Тятюшкин А.И. Численные методы и программные средства оптимизации управляемых систем / А.И. Тятюшкин. – Новосибирск: Наука, Сибирское отделение, 1992. – 193 с.
7. Floudas C.A., Pardalos P.M. A Collection of Test Problems for Constrained Global Optimization Algorithms. Springer-Verlag, 1990, 180 p.
8. Hock W., Schittkowski K. Test Examples for Nonlinear Programming Codes. Berlin: Springer, 1981, 177 p.
9. Betts J.T. A collection of optimal control test problems. 2015. Available at: <https://mechatronics.ucmerced.edu/sites/g/files/ufvvjh1226/f/page/documents/prbook-john-betts.pdf> (accessed: 02/27/2026).
10. Двуреченский А.В. Квантовые логические операции на спиновых состояниях в непрерывном СВЧ-поле / А.В. Двуреченский, А.Ю. Горнов, Т.С. Зароднюк, и др // Микроэлектроника. 2018. – Т. 47. – №4. – С. 49–58
11. Горнов А.Ю. Технология параллельной оптимизации для атомно-молекулярных кластеров Морса / А.Ю. Горнов, А.С. Аникин, П.С. Сороковиков, и др // Информационные и математические технологии в науке и управлении. 2021. – №4(24). – С. 60–67.
12. Efimova N.V., Bobkova E.V., Zarodnyuk T.S. et al. Age trend in the mortality from diseases of the circulatory system during the pandemic under a decrease in air pollution. Gigiena i Sanitariya, 2024, vol. 103, no 9, pp. 925–931.

**Зароднюк Татьяна Сергеевна.** Кандидат технических наук, зав. лабораторией Оптимального управления Институт динамики систем и теории управления им. В.М. Матросова СО РАН. Scopus AuthorID: 42462876400, AuthorID: 520189, SPIN: 2042-5313, ORCID: 0000-0003-2170-689X. tz@icc.ru. Россия, Иркутск, ул. Лермонтова, 134, а/я 292.

UDC 517.977.58

DOI:10.25729/ESI.2026.42.2.014

## Specialized algorithms and software for optimizing nonlinear controlled dynamical systems

Tatiana S. Zarodnyuk

Matrosov Institute for System Dynamics and Control Theory SB RAS, Russia, Irkutsk, tz@icc.ru

**Abstract.** The developed algorithms for solving nonlinear optimal control problems and approximating non-convex reachable sets formed the basis for specialized software constructed for studying nonlinear controlled

dynamical systems. Such systems arise in various scientific, technical, and industrial fields and are characterized by a high degree of complexity (nonlinear dynamical systems and non-convex objective functionals). Therefore, their effective solution requires the use of algorithms that take into account the specific characteristics of these problems. The paper proposes appropriate computational technologies based on both classical approaches based on sequential discretization of continuous problems and the application of Pontryagin's maximum principle, as well as on the specific properties of the dynamical systems, such as the linear connectivity of the reachable set and the hidden convexity of the admissible velocities set of controlled dynamical systems. Pre-optimization analysis methods (estimating the degree of the objective functionals convexity and constructing the boundary of the reachable set) are also implemented as programs that allow for the initial assessment of the computational complexity of applied non-convex optimization problems and the selection of effective numerical methods for their solution. Descriptions of the mathematical, software, and technological formulations of studied non-convex optimal control problems are provided. A framework for synthesizing multi-method non-local algorithms for optimizing controlled dynamical systems is presented.

The stages of constructing the computational scheme and the specifics of selecting algorithmic parameter values are described. A developed test collection of nonlinear optimal control problems is used to test software implementations of non-convex optimization algorithms to study their limiting properties and find effective modifications. The collection includes both published problems with known solutions and problems generated using the proposed test generation methodology. The developed algorithms and corresponding software were used to solve practical problems in various scientific and technical fields: flight dynamics and space navigation, quantum physics and computational chemistry, synthesis of composite structures, economics, medicine, technical ecology, and other areas.

**Keywords:** algorithms for non-convex optimization, optimal control problems, nonlinear controlled dynamical systems

**Acknowledgements:** The research was carried out at the expense of the state assignment within the framework of the topic "Evolutionary and Dynamic Controlled Systems: Theory, Numerical Methods, and Applications" (scientific code FWEW-2026-0011, No.~ registration 126021217177-7).

### References

1. Zarodnyuk T., Gornov A. Monowave boundary construction method for the non-convex reachable set of the controlled dynamical system. Springer Proceedings in Mathematics & Statistics: International Conference on Optimization, Simulation and Control (Ulaanbaatar, Mongolia, June 20–22, 2023), 2023, vol. 434, pp. 117–127, DOI: 10.1007/978-3-031-41229-5\_9
2. Gornov A.Yu., Zarodnyuk T.S., Anikin A.S. et al. Extension technology and extrema selections in a stochastic multistart algorithm for optimal control problems. Journal of Global Optimization, 2020, vol. 76, no. 3, pp. 533–543, DOI: 10.1007/s10898-019-00821-x
3. Gornov A.Yu., Zrodnyuk T.S. Metod sluchajny`x pokry`tij dlya zadachi optimal`nogo upravleniya [Stochastic covering method for optimal control problem]. Vychislitel'nyye tekhnologii [Computational technologies], vol. 17, no 2, pp. 31–42.
4. Zarodnyuk T.S. Algoritm chislennogo resheniya mnogoe`kstremal`ny`x zadach optimal`nogo upravleniya s parallelepipedny`mi ogranicheniyami [An algorithm for the numerical solution of multi-extremal optimal control problems with parallelepiped constraints]. Vychislitel'nyye tekhnologii [Computational technologies], 2013, vol. 18, no. 2, pp. 46–54.
5. Gornov, A.Yu. Vy`chislitel`ny`e tekhnologii resheniya zadach optimal`nogo upravleniya [Computational technologies for solving optimal control problems]. Novosibirsk, Nauka, 2009, 279 p.
6. Tyatyushkin A.I. Chislenny`e metody` i programmny`e sredstva optimizacii upravlyaemy`x sistem [Numerical methods and software for optimization of controlled systems]. Novosibirsk, Nauka, 1992, 193 p.
7. Floudas C.A., Pardalos P.M. A Collection of Test Problems for Constrained Global Optimization Algorithms. Springer-Verlag, 1990, 180 p.
8. Hock W., Schittkowski K. Test Examples for Nonlinear Programming Codes. Berlin: Springer, 1981, 177 p.
9. Betts J.T. A collection of optimal control test problems. 2015. Available at: <https://mechatronics.ucmerced.edu/sites/g/files/ufvvh1226/f/page/documents/prbook-johnbetts.pdf> (accessed: 02/27/2026).
10. Dvurechenskii A.V., Gornov A.Yu., Zarodnyuk T.S. et al. Kvantovyye logicheskiye operatsii na spinovykh sostoyaniyakh v nepreryvnom SVCh-pole [Quantum logic operations on spin states in a continuous microwave field]. Mikroelektronika [Russian Microelectronics], 2018, vol. 47, no. 4, pp. 49–58. (English version: Zinovieva A.F., Nenashev A.V., Koshkarev A.A., Zarodnyuk T.S., Gornov A.Y., Dvurechenskii A.V. Quantum gates with

- spin states in continuous microwave field. *Russian Microelectronics*, 2018, vol. 47, no. 4, pp. 268–278, DOI: 10.1134/S1063739718040147.)
11. Gornov A.Yu., Anikin A.S., Sorokovikov P.S. et al. *Texnologiya parallel'noj optimizacii dlya atomno-molekulyarny`x klasterov Morsa* [Parallel optimization technology for atomic-molecular Morse clusters]. *Informatsionnyye i matematicheskiye tekhnologii v nauke i upravlenii* [Information and mathematical technologies in science and management], 2021, no 4 (24), pp. 60–67.
  12. Efimova N.V., Bobkova E.V., Zarodnyuk T.S. et al. Age trend in the mortality from diseases of the circulatory system during the pandemic under a decrease in air pollution. *Gigiena i Sanitariya*, 2024, vol. 103, no 9, pp. 925–931.

**Zarodnyuk Tatiana Sergeevna.** *PhD, Head of The Laboratory of Optimal Control is Matrosov Institute for System Dynamics and Control Theory SB RAS. Scopus AuthorID: 42462876400, AuthorID: 520189, SPIN: 2042-5313, ORCID: 0000-0003-2170-689X. tz@icc.ru. Russia, Irkutsk, Lermontov Street, 134.*

*Статья поступила в редакцию 13.05.2026; одобрена после рецензирования 18.05.2026; принята к публикации 25.05.2026.*

*The article was submitted 05/13/2026; approved after reviewing 05/18/2026; accepted for publication 05/25/2026.*

УДК 004.89

DOI:10.25729/ESI.2026.42.2.015

## Создание проблемно-ориентированных ассистентов для задач диагностики

Дородных Никита Олегович<sup>1</sup>, Столбов Александр Борисович<sup>1,2</sup>,

Юрин Александр Юрьевич<sup>2,3</sup>

<sup>1</sup>Институт динамики систем и теории управления имени В.М. Матросова СО РАН, Россия, Иркутск, *nikidorny@icc.ru*

<sup>2</sup>Иркутский национальный исследовательский технический университет, Россия, Иркутск

<sup>3</sup>Московский государственный технический университет гражданской авиации (Иркутский филиал), Россия, Иркутск

**Аннотация.** В настоящее время виртуальные ассистенты, или интеллектуальные помощники, активно используются в различных предметных областях, но широкое их применение при решении задач технической диагностики ограничено. Подобные ограничения связаны в большей степени с правдоподобным характером генерируемых рекомендаций. Одним из способов повышения достоверности рекомендаций является применение классических методов искусственного интеллекта, в частности, реализующих достоверный вывод на основе логических правил. В статье описывается процесс построения проблемно-ориентированных ассистентов, использующих декларативные базы знаний в форме специализированных таблиц решений для решения задач диагностики технических систем. В качестве методологической основы используется оригинальный подход, основанный на визуальном моделировании и модельных трансформациях. Представлен обобщенный алгоритм диагностирования, включающий шаги по конкретизации исследуемого объекта, внешних проявлений неисправности, поиска возможных причин (систем-кандидатов на отказ), а также формированию списка работ по устранению неисправности. Алгоритм предполагает использование декларативных баз знаний, содержащих логические правила трех типов: «проявление-система», «работа-работа», «прецедент». Описана принципиальная архитектура ассистентов на основе концепции каркаса (шаблона) с гнездами (слотами) для подключения баз знаний с правилами определенного типа. Представлены требования к структуре и содержанию баз знаний; а также способы их наполнения. Определен стек технологий: *AIMylogic JUST AI* – для проектирования диалога; *PHP* – для реализации программных интерфейсов доступа к базам знаний; формат *CSV* – для описания логических правил в виде таблиц решений. Применение описанных положений осуществлено при создании прототипа интеллектуального ассистента «АвиаТехПом.Ассистент» для поддержки технических специалистов аэродромных наземных служб. Были созданы базы знаний для отдельных систем Сухой Суперджет (RRJ-95) и Cessna (182T). Особенностью полученного решения является его соответствие принципам декларативной парадигмы программирования, что обеспечивает возможность его перенастройки или адаптации в зависимости от типа воздушного судна или версии документации без полной регенерации или пересборки.

**Ключевые слова:** поддержка принятия решений, авиационная диагностика, виртуальный ассистент, база знаний, таблица решений, способ создания, АвиаТехПом.Ассистент

**Цитирование:** Дородных Н.О. Создание проблемно-ориентированных ассистентов для задач диагностики / Н.О. Дородных, А.Б. Столбов, А.Ю. Юрин // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 190-205. – DOI:10.25729/ESI.2026.42.2.015.

**Введение.** Виртуальные ассистенты, или интеллектуальные помощники, стали одной из современных технологий, активно применяемой для поддержки принятия решений в различных областях человеческой деятельности [1, 2]. В последнее десятилетие ведущие мировые ИТ-компании активно развивали собственные варианты интеллектуальных помощников преимущественно в рамках человеко-ориентированного подхода: Siri, Alexa, Алиса, Google Assistant и др. Существует большое количество инструментальных платформ для разработки таких помощников: Amazon Lex, Actions on Google, SiriKit, Microsoft Bot Framework, Rasa Stack, JUST AI, WoodBows, Virtualent, 24/7 Virtual Assistant и др., при этом создаваемые решения в основном ориентированы на поиск и представление информации. Применение методов генеративного искусственного интеллекта (ИИ) позволило качественно и количественно изменить характер решаемых ассистентами задач. В настоящее время

наблюдается взрывной рост в этом направлении: количество больших языковых моделей и интеллектуальных чат-ботов измеряется десятками (ChatGPT, LLaMA 2, PalmYGPT, GigaChat и др.).

К типовым задачам, решаемым этими системами, относятся [3, 4]: генерация текста (статей, рассказов, рекламы, кода), в том числе с учётом контекста; взаимодействие с пользователем (ответы на вопросы, поддержка диалога и обмена информацией); обработка текста (машинный перевод между языками, подсказки и завершение текста, классификация текста по темам или категориям); генерация мультимедийного контента (изображений или текстовых описаний, сценариев, диалогов); анализ данных и прогнозирование (анализ тональности и сентимента текста, прогнозирование трендов и анализ данных); персонализация и рекомендации (персонализированные рекомендации для пользователей на основе контекста и предпочтений).

При этом ассистенты недостаточно широко используются при решении задач технической диагностики [5], что обусловлено, в том числе, следующим факторами: предметные данные и знания содержатся в ограниченном пространстве технической документации, большей частью слабоструктурированной; ошибки в решениях (а также их недостоверность, например, в результате «галлюцинаций» интеллектуальных систем, построенных на основе генеративного ИИ) недопустимы и критичны. Перспективным способом преодоления указанных недостатков является применение при подготовке рекомендаций классических методов искусственного интеллекта, в частности, реализующих достоверный вывод на основе логических правил.

Одной из прикладных областей, эффективность решения задач в которой может быть повышена при помощи подобной технологии, является поддержка технических специалистов наземных служб при обслуживании авиационной техники [6-9]. При наличии программных систем в данной области [10, 11] новое решение в виде ассистента может быть рассмотрено как их расширение, используя общие информационные ресурсы в форме документации, баз данных и знаний.

Создание подобных систем требует непосредственного участия экспертов в процессе разработки, что также связано с различными проблемами извлечения знаний, частично преодолеть которые можно с использованием подходов, ориентированных на конечных пользователей, в частности, основанных на визуальном моделировании и модельных трансформациях [12-14]. Подходы к созданию программных систем, основанные на трансформации моделей, позволяют снизить требования к уровню подготовки разработчиков в области навыков программирования, ускорить процесс разработки и уменьшить количество ошибок, связанных как с кодированием, так и системным анализом задачи.

В статье рассматривается пример построения интеллектуального виртуального помощника АвиаТехПом.Ассистент [15] как расширения программно-алгоритмического обеспечения Авиационный Технический Помощник (АвиаТехПом) [16], разрабатываемого в Иркутском филиале МГТУ ГА при сотрудничестве с ИДСТУ СО РАН и Фондом содействия развитию малых форм предприятий в научно-технической сфере. Разработка осуществлялась с использованием специализации модельно-управляемого подхода (Model-Driven Engineering, MDE), ориентированной на создание производственных экспертных систем [17, 18].

Далее приведено краткое описание расширяемой платформы АвиаТехПом, примененного подхода, концептуальной архитектуры ассистента, используемых технологий. Особенностью полученного решения является возможность его перенастройки или адаптации в зависимости от типа воздушного судна или версии документации.

**1. Платформа «Авиационный технический помощник» (АвиаТехПом)** [16] представляет собой программно-алгоритмическое решение для поддержки принятия решений при поиске и устранении отказов и неисправностей на основе классических методов искусственного интеллекта [19-21] и математической теории принятия решений [22]. В качестве источника для формирования баз знаний использовалась как информация из технических руководств (РПУН – руководства по поиску и устранению неисправностей и РЭ – руководства по эксплуатации), так и опыт эксплуатации. АвиаТехПом обладает клиент-серверной архитектурой и включает следующие основные компоненты [16]:

1. АвиаТехПом.Репозиторий – хранилище предметной информации, реализованное на базе СУБД PostgreSQL с использованием микросервисной архитектуры технологии контейнеризации;
2. АвиаТехПом.Сервис – веб-приложение, реализующее основные функции поддержки принятия решений с доступом через браузер;
3. АвиаТехПом.Терминал – настольное приложение под ОС Windows, при решении задач может использовать как данные централизованного хранилища (АвиаТехПом.Репозиторий), так и локального хранилища в форме файлов в формате CSV (Comma-Separated Values);
4. АвиаТехПом.Ассистент – виртуальный ассистент [15] в форме чат-виджета.

В статье основное внимание уделено созданию АвиаТехПом.Ассистент с использованием модифицированной модельно-управляемой технологии [5].

**2. Технология на основе модельных трансформаций.** Подходы к созданию программных систем, основанные на трансформации концептуальных моделей [12, 13], как правило, позволяют более полно вовлечь предметных специалистов в процесс разработки путем использования принципов визуального моделирования, а также уменьшить количество ошибок, связанных с кодированием, за счет автоматической кодогенерации. Основная идея – использование в качестве артефактов процесса разработки различных концептуальных моделей с последующей их пошаговой трансформацией (преобразованием), с получением в результате других моделей большей степени конкретизации и привязки к целевой платформе, а также кодов и спецификаций. При этом под моделью понимается абстрактное представление программной системы, скрывающее информацию об определенных ее аспектах для упрощения восприятия пользователем и разработчиком. Модели визуализируются при помощи текстовых и графических языков, ориентированных на конечных пользователей. Подходы данного направления считаются дальнейшим развитием идеологии CASE-средств, можно выделить основные разновидности/реализации: архитектура, управляемая моделью (Model Driven Architecture, MDA) [23, 24] и проект консорциума OMG (Object Management Group) основанный на его основных стандартах; Eclipse Modeling Framework (EMF) [25] – активно использует программную платформу Eclipse, содержит средства создания метамodelей, их трансформаций и генерации спецификаций и кодов; Model-Integrated Computing (MIC) [26] – основана на использовании предметно-ориентированных языков моделирования (Domain-Specific Modeling Language, DSML) и технологической платформы MIC.

Авторами была разработана оригинальная специализация модельно-управляемой разработки [17, 18], ориентированная на создание производственных экспертных систем с декларативными базами знаний, основанная на принципах MDA. Отличием и новизной предлагаемого решения являлось: активное использование концепт-карт, онтологических шаблонов и оригинальной нотации RVML (Rule Visual Modeling Language) [27], в дополнение к диаграммам классов UML; ориентированность на моделирование

декларативных баз знаний, реализующих формализм логических правил; возможность кодогенации для CLIPS (C Language Integrated Production System), Drools и PHP (Hypertext PreProcessor). В дальнейшем она была расширена для создания виртуальных ассистентов [5] в части поддержки формализмов деревьев событий и диаграмм переходов состояний, а также новых целевых платформ. Приведем ее основные этапы:

- создание вычислительно-независимых моделей, обеспечивающих формулировку ключевых абстракций решаемой задачи, включая: общую (типовую) модель интеллектуального помощника, онтологию задач, онтологию предметной области и онтологию диалога;
- создание проблемно-ориентированных платформо-независимых моделей, учитывающих специфику решаемой задачи, включая базу знаний интеллектуального помощника и модель проблемно-ориентированного диалога;
- создание платформо-зависимых моделей, ориентированных на определенную программную платформу функционирования интеллектуального помощника;
- генерации кодов и спецификаций интеллектуального помощника, для определенной платформы.

Реализация данных этапов в прототипе инструментария [28] позволила создавать виртуальных ассистентов [29] в рамках императивной парадигмы программирования, особенностью которой является: включение логики поведения и предметных знаний в сгенерированный программный код; необходимость регенерации или пересборки приложений при изменении предметной области.

В контексте создания проблемно-ориентированных ассистентов перспективным является создание программно-алгоритмического решения, соответствующего декларативной парадигме программирования, в рамках которой: осуществлено разделение логики поведения и предметных знания; остается необходимость ограниченной регенерации отдельных компонентов приложений, а именно, баз знаний, при изменении предметной области.

### **3. Создание проблемно-ориентированного ассистента.**

**3.1. Обобщенный алгоритм диагностирования технических систем.** При решении задачи создания проблемно-ориентированного ассистента был предложен обобщенный алгоритм его функционирования для диагностирования технических систем (рис. 1), включающий следующие шаги, определяющие его функции:

- выбор/конкретизация (типа) технической системы;
- выбор/конкретизация определенной подсистемы;
- описание внешних проявлений неисправности;
- поиск систем-кандидатов (возможные причины неисправности);
- формирование списка работ по устранению неисправности;
- последовательное выполнение работ с контролем их результатов;
- фиксация окончательного результата в форме прецедента (единицы опыта решения задачи).

В контексте прикладной задачи авиационной диагностики при конкретизации алгоритма под технической системой понимается воздушное судно определенного типа, а под подсистемой – система этого воздушного судна.

При выполнении отдельных шагов алгоритма (рис.1) целесообразно использование декларативных баз знаний, описывающих: внешние проявления неисправности и системы;

внешние проявления неисправности и работы; прецеденты. Фактически формируются логические правила трех типов: «проявление-система», «работа-работа», «прецедент».

**3.2. Архитектура и функции.** Следуя декларативной парадигме создания проблемно-ориентированного ассистента, было предложено использовать концепцию каркаса (шаблона) с гнездами (слотами) [30].



**Рис. 1.** Обобщенный алгоритм диагностирования

Формально, архитектура ассистента может быть представлена в следующем виде:  $A = \langle F, KB_{S-S}, KB_{O-O}, KB_C \rangle$ , где  $F$  – каркас;  $KB_{S-S}$  – гнездо для базы знаний с описанием зависимостей типа «проявление-система»;  $KB_{O-O}$  – гнездо для базы знаний с описанием зависимостей типа «работа-работа»;  $KB_C$  – гнездо для базы знаний с описанием прецедентов.

При этом основное назначение каркаса состоит в унифицированной реализации:

- обобщенного алгоритма в форме последовательных диалоговых экранов;
- взаимодействия с базами знаний в части отправки запросов и получения результатов.

К гнездам (слотам) подключаются файлы баз знаний.

**3.3. Представление баз знаний.** Для представления знаний было предложено использовать оригинальную форму таблиц решений [31], основными отличиями которой от классической [32] являются:

- индикация зависимых столбцов символом «#»;
- одноуровневая иерархия в условиях «плоских» таблиц в формате CSV путем указания составных имен столбцов, включающих имя сущности (или имя класса сущностей) и наименования ее свойства, разделенных строкой «:»;
- поддержка использования произвольных значений в качестве значений ячеек, а не только указывающих на наличие или отсутствие определенного свойства (компонента) в структуре правила (да/нет или 0/1).

При этом для описания основных типов правил (рис. 2) на основе ранее разработанной модели предметной области [33] была определена структура таблиц решений со следующими ограничениями:

- наличие совпадающих по наименованию полей антецедента (условия) логических правил и части «описание проблемы» прецедента, что необходимо для поиска решения по одинаковому набору внешних проявлений или диагностических признаков, формирующих «контекст» применения правил;
- обязательное наличие полей: «Работа:Наименование»/«Наименование», «Работа::Результат»/«Результат», «#Работа::Наименование»/«#Наименование» в структуре правил «работа-работа», с помощью которых формируются взаимосвязи при построении последовательных цепочек выполнения.




Рис. 2. Структура основных типов правил проблемно-ориентированного ассистента [31]

### 3.4. Модификация (наполнение) баз знаний. Применяемая технология [18]

предполагает использование и доработку ряда инструментальных средств, обеспечивающих решение задачи модификации или наполнения базы знаний и ориентированных на пользователей с низкими навыками программирования, в частности:

- Редактора продукционных баз знаний Personal Knowledge Base Designer (PKBD) [34] (Рис.3).
- Веб-ориентированной программной системы Knowledge Modeling System (KMS) [35] (Рис.4), в частности, редактора диаграмм переходов состояний.
- Средств программы-оболочки iDSS.Desktop [36]: редакторов таблиц решений и ориентированных графов (Рис.5).




Рис. 3. Примеры экранных форм PKBD: просмотр правила в виде диаграммы RVML

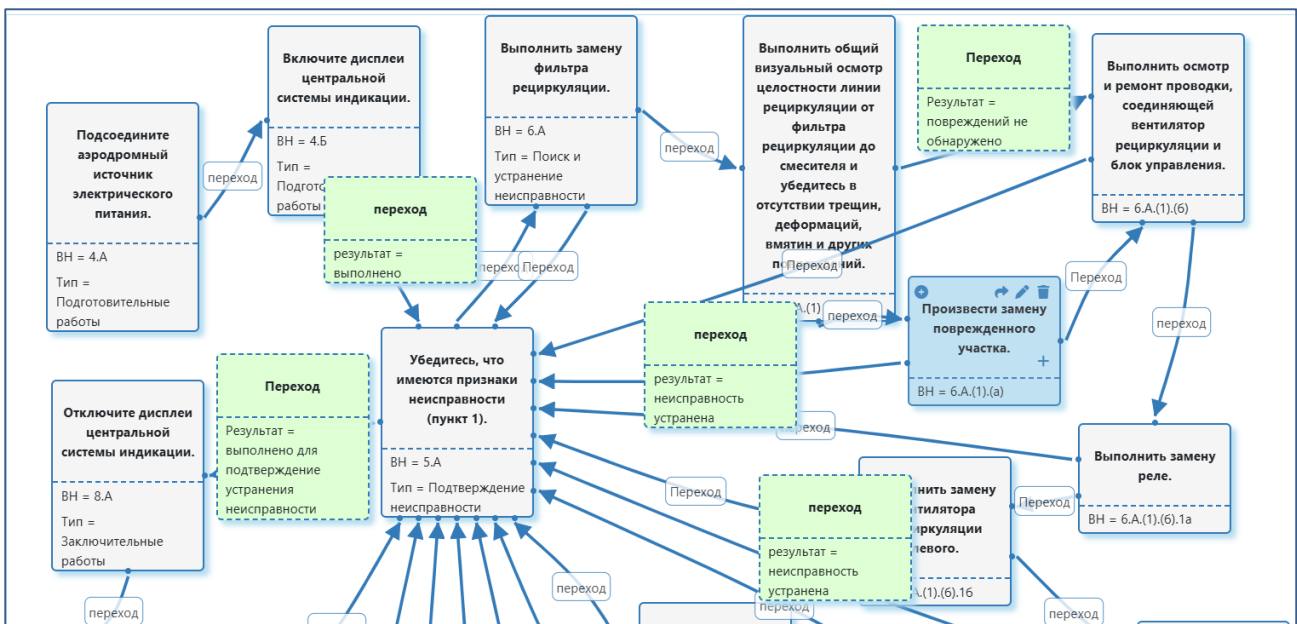


Рис. 4. Примеры экранной форм KMS: редактор диаграмм переходов состояний [40]

ID	SIGNS1	SIGNS2	Система
1	INSUFFICIENT REFRIGERANT CHARGE	Insufficient cooling. Bubbles appear in sight glass	AIR-CONDITIONING SYSTEM
2	INSUFFICIENT REFRIGERANT CHARGE	Insufficient cooling. Bubbles appear in sight glass	AIR-CONDITIONING SYSTEM
3	INSUFFICIENT REFRIGERANT CHARGE	Insufficient cooling. Bubbles appear in sight glass	AIR-CONDITIONING SYSTEM
4	INSUFFICIENT REFRIGERANT CHARGE	Insufficient cooling. Bubbles appear in sight glass	AIR-CONDITIONING SYSTEM
5	INSUFFICIENT REFRIGERANT CHARGE	Insufficient cooling. Bubbles appear in sight glass	AIR-CONDITIONING SYSTEM
6	ALMOST NO REFRIGERANT	No cooling action. A lot of bubbles or something like mist appears in sight glass	AIR-CONDITIONING SYSTEM

Рис. 5. Примеры экранных форм iDSS.Desktop: редакторы таблиц решений и графов

Также были использованы общедоступные табличные редакторы Microsoft Excel и LibreOffice Calc. По результатам сравнения использованных средств (Таблица 1) в качестве основных были выбраны KMS и iDSS.Desktop: обе программные системы продемонстрировали возможность визуализации разветвленных сценариев для правил типа «работа-работа» и достаточно низкое количество ошибок.

**3.5. Диалоговая система.** Одной из отличительных особенностей современных виртуальных ассистентов является возможность поддерживать диалог с пользователем на естественном языке с учётом контекста решаемой задачи. Для определения намерений пользователя и извлечения из его сообщений данных, необходимых для решения задач, был использован подход на основе фреймов. Согласно этому подходу, разработчик должен сформировать спецификацию разговорного интерфейса, указав множество намерений и

сущностей, которые необходимо извлекать из сообщений пользователя; шаблоны для значений сущностей и/или множество синонимов значений; соответствующие намерениям типовые фразы и/или их шаблоны.

**Таблица 1.** Качественное сравнение программных средств модификации (наполнения) баз знаний в форме таблиц решений

Средства/ Критерии сравнения	PKBD	KMS	iDSS.Desktop	Microsoft Excel / LibreOffice Calc
Основная технология	Программы-мастера (последовательности диалоговых форм)	Графические модели	Графические модели, таблицы	Таблицы
Интеграция со сторонними средствами (импорт/экспорт)	Высокая	Высокая	Средняя	Слабая
Доступность для непрограммирующих конечных пользователей	Средняя	Высокая	Средняя	Высокая
Средства контроля целостности	Да	Нет	Да	Нет
Средства автоматизации ввода	Да (копирование правил)	Да (копирование моделей)	Да (копирование правил, продолжение цепочек)	Да (копирование и вставка текста)
Возможность тестирования (логического вывода)	Да	Нет	Да	Нет
Визуализация ветвлений	Нет	Да	Да	Нет
Количество ошибок	Низкое	Низкое	Низкое	Высокое

В рамках этой работы спецификация разговорного интерфейса фреймового типа для проблемно-ориентированных ассистентов в задачах диагностики содержит информацию для алгоритмов классификатора NLU по определению намерений, фреймов и слотов из словесного описания:

- наблюдаемых признаков неисправностей, в т.ч. кодов неисправностей;
- результатов работы, выполненной техником (примеры: «неисправность обнаружена», «неисправности нет», «работа выполнена», «произведено»);
- инструкций для базовых команд управления процессом диалога со стороны пользователя (авторизация, помощь, аварийная остановка диалога и т.п.).

В отличие от встроенных в современные платформы стандартных словарей, используемых при распознавании намерений пользователя, в разработанном разговорном интерфейсе учитываются следующие особенности, связанные с возможностью голосового ввода:

- Произношение латинских букв в кодах неисправностей. Пример оригинальных данных аварийно-сигнального сообщения: «ELEC APU GEN FAULT». Пример возможных фраз пользователя: «елек апу ген фолт», «елек апэу ген фолт», «елес апу ген фэулт», «елеклес апэу фэулт».

- Произношение чисел. Пример оригинальных данных: «код БСТО 1013». Пример возможных фраз пользователя: «Код БСТО десять тринадцать», «Код БСТО тысяча тринадцать», «Код БСТО тысяча тринадцатый».
- Некорректное произношение символов. Пример: «тильда», «волна», «змейка».

При формировании множества синоним и вариантов фраз была использована процедура аугментации данных, основанная на принципах современного генеративного ИИ в форме больших языковых моделей.

Процесс диалога рассматривался в форме множества иерархических состояний диалога, которые соответствуют следующим типам задач:

- анализ намерений пользователя;
- подготовка данных для их последующего использования в базе знаний;
- обработка результатов работы базы знаний для их представления пользователю в диалоговой форме;
- реализация технических процедур для взаимодействия с базой знаний;
- реагирование на внештатные ситуации, связанным с проблемами в распознавании пользовательских запросов, потерей соединения с удаленным сервером, невозможности авторизации;
- решение конфликтных ситуаций, связанных с несоответствием пользовательского запроса ожидаемым от него сообщениям относительно текущего состояния решаемой задачи.

**3.6. Программная реализация.** Для создания проблемно-ориентированных ассистентов использовался следующий стек технологий:

- Визуальный конструктор интеллектуальных ассистентов Aimylogic JUST AI [37], с помощью которого был построен унифицированный проблемно-ориентированный диалог, соответствующий обобщенному алгоритму и включающий основные экраны взаимодействия с пользователем, а также вызов функций обмена информацией с базами знаний.
- Платформа JAICP JUST AI [38], реализующая гибридный подход для управления процессом диалога: на основе конечных автоматов и фреймов; содержащая собственную подсистему обработки естественного языка; обеспечивающая поддержку большого количества каналов для интеграции помощника. При этом программная реализация выполняется на скриптовом языке общего назначения JavaScript и проблемно-ориентированном языке JAICP DSL [39]. Использование JAICP JUST AI позволяет разрабатывать полностью новые или уточнять созданные в Aimylogic сценарии в случае необходимости реализации сложных многоуровневых актов взаимодействия с возможностью полного контроля сессии диалога.
- Язык общего назначения PHP (Hypertext Preprocessor) для реализации программных интерфейсов доступа к базам знаний, основные функции: поиск (извлечение) прецедентов; сравнение значений свойств прецедентов; получение списка возможных причин (систем-кандидатов); получение наиболее вероятного внешнего проявления, на основе введенного пользователем; формирование списка типов технических систем; формирование списка систем определенной технической системы и др.;
- формат CSV для описания логических правил в виде таблиц решений.

**4. Пример применения: АвиаТехПом.Ассистент.** Апробация подхода осуществлялась при создании виртуального ассистента – АвиаТехПом.Ассистент [15] (рис.

б) для гражданских воздушных судов Сухой Суперджет (RRJ-95) и Cessna (182T), количественные характеристики разработанных баз знаний приведены в Таблице 2 [40].




Рис. 6. Примеры экранных форм AviaTechPom.Assistent

Таблица 2. Количественные характеристики баз знаний AviaTechPom.Assistent

Тип воздушного судна	Система	Количество правил типа «работа-работа»	Количество правил типа «проявление-система»
RRJ-95	электроснабжения	828	173
RRJ-95	кондиционирования	687	178
Cessna 182T	кондиционирования	52	22

Результаты апробации могут быть рассмотрены с двух точек зрения повышения эффективности: 1) создания проблемно-ориентированных ассистентов и их баз знаний; 2) решения предметной задачи технического обслуживания и ремонта.

В рамках первого аспекта повышение эффективности по временному критерию достигается за счет использования определенного «шаблона» или каркаса проблемно-ориентированного ассистента, а общее время создания определяется протяженностью этапа разработки базы знаний. Оценки выполнения данного этапа на реальных данных и учебных примерах проводились при создании специализации модельно-управляемой технологии [18], она показала возможность сокращения времени разработки на 25-60% в зависимости от объема и сложности исходных моделей предметной области за счет визуального моделирования и автоматической кодогенерации.

В рамках второго аспекта количественные оценки эффекта от использования «AviaTechPom.Assistent» будут получены только после внедрения в процессе эксплуатации. На текущий момент возможно руководствоваться оценками эксплуатации частичного аналога – программной системы ЭСАН «Когнитолог» [41]. Эта система применялась для поддержки технических специалистов при обслуживании ТУ-204, что позволило уменьшить время на поиск и локализацию причин неисправности в среднем на 20-25% за счет автоматизации отдельных этапов процедуры диагностирования, в том числе, поиска релевантных разделов технической документации.

**Заключение.** Повышение оперативности и эффективности решения задач технической диагностики в различных областях, в том числе, гражданской авиации, может быть достигнуто за счет применения таких технологий, как виртуальные ассистенты, или интеллектуальные помощники. В свою очередь, одним из способов повышения доверия к подобным системам является использование логико-ориентированных методов искусственного интеллекта, а именно декларативных баз знаний и реализация достоверного вывода.

В статье рассмотрено создание проблемно-ориентированных ассистентов для задач диагностики на примере приложения (чат-виджета) АвиаТехПом.Ассистент [42]. В процессе разработки использовалась модифицированная модельно-управляемая технология [18] и принципы декларативного подхода. Представлен обобщенный алгоритм диагностирования технических систем, включающий шаги по конкретизации исследуемого объекта (самолета и его подсистемы), внешних проявлений неисправности, поиска возможных причин, а также формированию списка работ по устранению неисправности. Алгоритм предполагает использование декларативных баз знаний, описывающих: внешние проявления неисправности, системы, работы, прецеденты. Рассмотрены способы формирования баз знаний на основе специализированных таблиц решений, ограничения на их структуру и содержание.

При апробации были созданы базы знаний для различных типов воздушных судов и их отдельных систем, что показало перспективность предлагаемого подхода. В дальнейшем планируется апробировать подход на данных об исследовании технического состояния объектов нефтехимии [43].

**Благодарности.** Работа выполнена в рамках госзадания Минобрнауки России по проекту «Методы и технологии облачной сервис-ориентированной цифровой платформы сбора, хранения и обработки больших объёмов разноформатных междисциплинарных данных и знаний, основанные на применении искусственного интеллекта, компонентного и модельно-управляемого подходов и машинного обучения» (126021217141-8).

#### Список источников

1. Sarikaya R. The Technology Behind Personal Digital Assistants: An overview of the system architecture and key components. *IEEE Signal Processing Magazine*, 2017, vol. 34 (1), pp. 67–81, DOI: 10.1109/MSP.2016.2617341.
2. Norouzi N., Kim K., Hochreiter J. et al. A Systematic Survey of 15 Years of User Studies Published in the Intelligent Virtual Agents Conference. *Proceedings of IVA'18: International Conference on Intelligent Virtual Agents, Sydney*, 2018, pp. 17–22, DOI: 10.1145/3267851.3267901.
3. Parizi R., Shahi A. Component-Driven Development in Modern Virtual Assistants: A Mapping Study. *Journal of Software*, 2018, no. 13, pp. 126–137, DOI:10.17706/jsw.13.2.126-137.
4. Maedche A., Legner C., Benlian A. et al. AI-Based Digital Assistants. *Business and Information Systems Engineering*, 2019, vol. 61, pp. 535–544, DOI: 10.1007/s12599-019-00600-8.
5. Dorodnykh N.O., Nikolaychuk O.A., Stolbov A.B. et al. Creating Virtual Assistants Based on Model Transformations. *Pattern Recognition and Image Analysis*, 2024, vol. 34(3), pp. 692–701, DOI:10.1134/S1054661824700548.
6. Kotlov Y., Popov V., Mishin S. et al. Towards an Intelligent Decision Support System for Aircraft Troubleshooting. *Lecture Notes in Mechanical Engineering*, 2023, pp. 77-91, DOI:10.1007/978-981-19-3788-0\_7.
7. Перфильев О.В. Интеллектуальная система поиска неисправности на самолете / О.В. Перфильев, С.Г. Рыжаков, В.А. Должиков // *Известия Самарского научного центра РАН*, 2018. – № 4(3). – С. 326-331.
8. Сухих Н.Н. Экспертные системы – средства информационной поддержки принятия решений экипажем самолета / Н.Н. Сухих, В.Л. Рукавишников // *Известия высших учебных заведений. Авиационная техника*, 2022. – № 2. – С. 19-25.
9. Chiu C., Chiu N.H., Hsu C.I. Intelligent aircraft maintenance support system using genetic algorithms and case-based reasoning. *International Journal of Advanced Manufacturing Technology*, 2004, vol. 24, pp. 440–446, DOI:10.1007/s00170-003-1707-x.
10. MyBoeing Fleet. Available at: <https://www.myboeingfleet.com> (accessed: 11/20/2025).
11. AirNav-Maintenance. Available at: <https://www.airnav.com> (accessed: 11/20/2025).
12. Da Silva A.R. Model-driven engineering: A survey supported by the unified conceptual model. *Computer Languages, Systems & Structures*, 2015, vol.43, pp. 139–155, DOI:10.1016/j.cl.2015.06.001.
13. Pérez-Soler S., Guerra E., De Lara J. Model-Driven Chatbot Development. *Lecture Notes in Computer Science*, 2020, vol. 12400, pp. 207–222, DOI:10.1007/978-3-030-62522-1\_15.

14. Benaddi L., Ouaddi C., Jakimi A. et al. A Survey on Model-Driven Engineering and Domain-Specific Languages for Chatbot Development: Requirements, Challenges and Solutions. *Expert systems*, 2025, vol.42(10), 70124.
15. Юрин А.Ю. АвиаТехПом.Ассистент / А.Ю. Юрин // Свидетельство о государственной регистрации программы для ЭВМ. – М. – Рег. № 2025616049 от 13.03.25.
16. Юрин А.Ю. АвиаТехПом: Состояние и перспективы / А.Ю. Юрин, Ю.В. Котлов // *Crede Experto: транспорт, общество, образование, язык*, 2024. – № 1. – С. 146-156.
17. Yurin A.Yu., Dorodnykh N.O., Nikolaychuk O.A. et al. Designing rule-based expert systems with the aid of the model-driven development approach. *Expert Systems*, 2018, vol.35(1), 12291.
18. Дородных Н.О. Технология создания производственных экспертных систем на основе модельных трансформаций / Н.О. Дородных, А.Ю. Юрин. – Новосибирск: СО РАН, 2019.
19. Варшавский П.Р. Моделирование рассуждений на основе прецедентов в интеллектуальных системах поддержки принятия решений / П.Р. Варшавский, А.П. Еремеев // *Искусственный интеллект и принятие решений*, 2009. – № 2. – С. 45-57.
20. Джексон П. Введение в экспертные системы. – М.: Вильямс, 2001. – 623 с.
21. Aamodt A., Plaza E. Case-based reasoning: foundational issues, methodological variations, and system approaches. *AI Communications*, 1994, vol.7(1), pp. 39-59.
22. Котлов Ю.В. Модели и алгоритмы многокритериальной диагностики авиационных систем // *Актуальные проблемы и перспективы развития гражданской авиации: сборник трудов XI Международной научно-практической конференции*. – Иркутск, 2022. – С. 165-173.
23. Frankel D. *Model Driven Architecture: Applying MDA to Enterprise Computing*. New York: Wiley, 2003, 328 p.
24. Truyen F. *The Fast Guide to Model Driven Architecture: The Basics of Model Driven Architecture*. Cephas Consulting Corp, 2006, 12 p.
25. Eclipse Modeling Framework (EMF). Available at: <http://www.eclipse.org/modeling/emf/> (accessed: 11/20/2025).
26. Model-Integrated Computing (MIC). Available at: <http://www.isis.vanderbilt.edu/research/MIC> (accessed: 11/20/2025).
27. Юрин А.Ю. Нотация для проектирования баз знаний производственных экспертных систем / А.Ю. Юрин // *Объектные системы*, 2016. – № 12. – С. 48–54.
28. Столбов А.Б. Генерация и трансформация специализированных моделей для проблемно-ориентированного интеллектуального помощника / А.Б. Столбов, Н.О. Дородных, О.А. Николайчук, и др. // *Ляпуновские чтения 2023: материалы 39-й международной конференции*. – Иркутск, 2023. – С. 111-112.
29. Yurin A.Yu., Nikolaychuk O.A., Dorodnykh N.O. et al. Using an Intelligent Assistant for Aircraft Diagnostics and Maintenance. *Lecture Notes in Networks and Systems*, 2023, vol. 776, pp. 325-333, DOI:10.1007/978-3-031-43789-2\_30.
30. Горбунов-Посадов М.М. *Расширяемые программы*. – М.: Полиптих, 1999. – 336 с.
31. Дородных Н.О. Создание диагностических систем поддержки принятия решений с использованием таблиц решений / Н.О. Дородных, О.А. Николайчук, Ю.В. Котлов, А.Ю. Юрин // *Искусственный интеллект и принятие решений*, 2025. – № 3. – С. 15-29.
32. Еремеев А.П. Производственная модель представления знаний на базе языка таблиц решений // *Известия АН СССР. Техническая кибернетика*, 1987. – № 2. – С. 196-207.
33. Дородных Н.О. Использование онтологических шаблонов содержания при построении баз знаний для технического обслуживания и ремонта авиационной техники / Н.О. Дородных, О.А. Николайчук, А.Ю. Юрин // *Онтология проектирования*, 2022. – Т. 12, № 2. – С. 158-171.
34. Personal Knowledge Base Designer. Available at: <http://www.knowledge-core.ru/index.php?p=pkbd> (accessed: 11/20/2025).
35. Knowledge Modeling System. Available at: <http://kms.knowledge-core.ru/> (accessed: 11/20/2025).
36. iDSS.Desktop. Available at: <http://www.knowledge-core.ru/index.php?p=idss> (accessed: 11/20/2025).
37. Visual builder for AI-powered bots. Aimylogic Available at: <https://aimylogic.com/> (accessed: 11/20/2025).
38. A convenient platform for creating and developing conversational AI solutions. Available at: <https://just-ai.com/platforma-jaicp> (accessed: 11/20/2025).
39. JAICP DSL. Available at: <https://help.cloud.just-ai.com/en/jaicp/dsl/> (accessed: 11/20/2025).
40. Дородных Н.О. О подходе к построению баз знаний для задач авиационной диагностики / Н.О. Дородных, О.А. Николайчук, Ю.В. Котлов, А.Ю. Юрин // *Известия высших учебных заведений. Авиационная техника*, 2025. – № 1. – С. 131-139.

41. Перфильев О.В. Экспертная система анализа причин неисправностей для авиационной техники / О.В. Перфильев, С.Г. Рыжаков // Известия Самарского научного центра Российской академии наук, 2016. – Т. 18, № 4-3. – С. 564-570.
42. АвиаТехПом.Ассистент. – URL: [https://www.altair-ii.ru/index.php?p=atp\\_assistant](https://www.altair-ii.ru/index.php?p=atp_assistant) (дата обращения: 20.11.2025).
43. Берман А.Ф. Деградация механических систем. – Новосибирск: Наука, 1998. – 320 с.

*Дородных Никита Олегович. К.т.н., старший научный сотрудник Института динамики систем и теории управления им. В.М. Матросова СО РАН (ИДСТУ СО РАН). Основные направления исследований: автоматизация создания интеллектуальных систем и баз знаний, получение знаний из документов, таблиц, концептуальных моделей, семантическая интерпретация таблиц. SPIN: 1922-2224, ORCID: 0000-0001-7794-4462; Author ID (RSCI): 979843; Author ID (Scopus): 57202323578; Researcher ID (WoS): E-8870-2014. nikedorny@icc.ru.*

*Столбов Александр Борисович. К.т.н., научный сотрудник ИДСТУ СО РАН, доцент Института информационных технологий и анализа данных ИРНИТУ. Основные направления исследований: системный анализ, математическое и имитационное моделирование многокомпонентных систем, разработка виртуальных ассистентов. SPIN: 9524-6300, ORCID: 0000-0001-6513-7030; Author ID (RSCI): 185900; Author ID (Scopus): 57119776700; Researcher ID (WoS): A-6478-2014. stolboff@icc.ru.*

*Юрин Александр Юрьевич. Д.т.н., заведующий лабораторией Информационно-телекоммуникационных технологий исследования природной и техногенной безопасности ИДСТУ СО РАН, профессор Института информационных технологий и анализа данных ИРНИТУ, ведущий научный сотрудник кафедры АЭСиПНК Иркутского филиала МГТУ ГА. Основные направления исследований: разработка интеллектуальных систем и баз знаний, достоверный и правдоподобный вывод, модельно-управляемая разработка, визуальное программирование. SPIN: 5830-7930, ORCID: 0000-0001-9089-5730; Author ID (RSCI): 174845; Author ID (Scopus): 16311168300; Researcher ID (WoS): A-4355-2014. iskander@icc.ru.*

---

UDC 004.89

DOI:10.25729/ESI.2026.42.2.015

## Creating domain-specific assistants for diagnostic tasks

Nikita O. Dorodnykh<sup>1</sup>, Aleksandr B. Stolbov<sup>1,2</sup>, Aleksandr Yu. Yurin<sup>2,3</sup>

<sup>1</sup>Matrosov Institute for System Dynamics and Control Theory SB RAS,  
Russia, Irkutsk, [nikedorny@icc.ru](mailto:nikedorny@icc.ru)

<sup>2</sup>Irkutsk National Research Technical University, Russia, Irkutsk

<sup>3</sup>Moscow State Technical University of Civil Aviation (Irkutsk Branch), Russia, Irkutsk

**Abstract.** Currently, virtual assistants, or intelligent assistants, are actively used in various subject areas, but their widespread use in solving technical diagnostic problems is limited. Such limitations are mostly related to the plausible nature of the recommendations generated. One of the ways to increase the reliability of recommendations is to use classical artificial intelligence methods, in particular, those that implement reliable inference based on logical rules. The paper describes the process of building problem-specific assistants using declarative knowledge bases in the form of specialized decision tables to solve the problems of diagnosing technical systems. An original approach based on visual modeling and model transformations is used as a methodological basis. A generalized algorithm for diagnosing technical systems is presented, which includes steps to specify the object under study, the external manifestations of the malfunction, the search for possible causes (candidate systems for the malfunction), as well as the formation of a list of troubleshooting activities. The algorithm assumes the use of declarative knowledge bases containing logical rules of three types: "manifestation-system", "operation-operation", "case". The general architecture of assistants is described based on the concept of a template with sockets (slots) for connecting knowledge bases with rules of a certain type. The requirements for the structure and content of knowledge bases are presented, as well as ways to manage them. The technology stack is defined: Aimylogic JUST AI – for designing a dialog; PHP – for implementing

software interfaces for accessing knowledge bases; CSV format – for describing logical rules in the form of decision tables. The application of the described provisions was carried out when creating a prototype of the intelligent assistant "Aviatech.Assistant" to support the technical specialists of airfield ground services. Knowledge bases have been created for individual Sukhoi Superjet (RRJ-95) and Cessna (182T) systems. A special feature of the resulting solution is its compliance with the principles of the declarative programming paradigm, which allows one to reconfigure or adapt it depending on the type of aircraft or documentation version without complete regeneration or recompilation.

**Keywords:** decision support, aviation diagnostics, virtual assistant, knowledge base, decision table, creation, AviaTekhPom.Assistant

**Acknowledgements:** This work is supported by the Ministry of Science and Higher Education of the Russian Federation the project "Methods and technologies of a cloud-based service-oriented digital platform for collecting, storing, and processing large volumes of multi-format interdisciplinary data and knowledge based on the use of artificial intelligence, component, and model-driven approaches and machine learning." (126021217141-8).

## References

1. Sarikaya R. The Technology Behind Personal Digital Assistants: An overview of the system architecture and key components. *IEEE Signal Processing Magazine*, 2017, vol. 34 (1), pp. 67–81, DOI: 10.1109/MSP.2016.2617341.
2. Norouzi N., Kim K., Hochreiter J. et al. A Systematic Survey of 15 Years of User Studies Published in the Intelligent Virtual Agents Conference. *Proceedings of IVA'18: International Conference on Intelligent Virtual Agents, Sydney*, 2018, pp. 17–22, DOI: 10.1145/3267851.3267901.
3. Parizi R., Shahi A. Component-Driven Development in Modern Virtual Assistants: A Mapping Study. *Journal of Software*, 2018, no. 13, pp. 126–137, DOI:10.17706/jsw.13.2.126-137.
4. Maedche A., Legner C., Benlian A. et al. AI-Based Digital Assistants. *Business and Information Systems Engineering*, 2019, vol. 61, pp. 535–544, DOI: 10.1007/s12599-019-00600-8.
5. Dorodnykh N.O., Nikolaychuk O.A., Stolbov A.B. et al. Creating Virtual Assistants Based on Model Transformations. *Pattern Recognition and Image Analysis*, 2024, vol. 34(3), pp. 692–701, DOI:10.1134/S1054661824700548.
6. Kotlov Y., Popov V., Mishin S. et al. Towards an Intelligent Decision Support System for Aircraft Troubleshooting. *Lecture Notes in Mechanical Engineering*, 2023, pp. 77-91, DOI:10.1007/978-981-19-3788-0\_7.
7. Perfiliev O.V., Ryzhakov S.G., Dolzhikov V.A. Intellektual'naya sistema poiska neispravnosti na samolete [Intelligent aircraft troubleshooting system]. *Izvestiya Samarskogo nauchnogo centra RAN [Proceedings of the Samara Scientific Center of the Russian Academy of Sciences]*, 2018, no. 4(3), pp.326.
8. Sukhikh N.N., Rukavishnikov V.L. Expert Systems: Means of Information Support for Aircraft Crew Decision Making. *Russian Aeronautics*, 2022, vol. 65(2), pp.243–250, DOI:10.3103/S1068799822020039.
9. Chiu C., Chiu N.H., Hsu C.I. Intelligent aircraft maintenance support system using genetic algorithms and case-based reasoning. *International Journal of Advanced Manufacturing Technology*, 2004, vol. 24, pp. 440–446, DOI:10.1007/s00170-003-1707-x.
10. MyBoeing Fleet. Available at: <https://www.myboeingfleet.com> (accessed: 11/20/2025).
11. AirNav-Maintenance. Available at: <https://www.airnav.com> (accessed: 11/20/2025).
12. Da Silva A.R. Model-driven engineering: A survey supported by the unified conceptual model. *Computer Languages, Systems & Structures*, 2015, vol.43, pp. 139–155, DOI:10.1016/j.cl.2015.06.001.
13. Pérez-Soler S., Guerra E., De Lara J. Model-Driven Chatbot Development. *Lecture Notes in Computer Science*, 2020, vol. 12400, pp. 207–222, DOI:10.1007/978-3-030-62522-1\_15.
14. Benaddi L., Ouaddi C., Jakimi A. et al. A Survey on Model-Driven Engineering and Domain-Specific Languages for Chatbot Development: Requirements, Challenges and Solutions. *Expert systems*, 2025, vol.42(10), 70124.
15. Yurin A.Yu. AviaTexPom.Assistent [AviaTekhPom.Assistant]. Certificate of state registration of a computer program, no.2025616049, 13.03.25.
16. Yurin A.Yu., Kotlov Yu.V. AviaTexPom: Sostoyanie i perspektivy` [AviaTekhPom: State and prospects]. *Crede Experto: transport, obshchestvo, obrazovanie, yazyk [Crede Experto: transport, society, education, language]*, 2024, no.1, pp. 146-156.
17. Yurin A.Yu., Dorodnykh N.O., Nikolaychuk O.A. et al. Designing rule-based expert systems with the aid of the model-driven development approach. *Expert Systems*, 2018, vol.35(1), 12291.

18. Dorodnykh N.O., Yurin A.Yu. *Texnologiya sozdaniya produkcionny`x e`kspertny`x sistem na osnove model`ny`x transformacij* [Technology of creation of rule-based expert systems based on model transformations]. Novosibirsk, SB RAS, 2019.
19. Varshavsky P.R., Ereemeev A.P. *Modelirovaniye rassuzhdeniy na osnove pretsedentov v intellektual`nykh sistemakh podderzhki prinyatiya resheniy* [Modeling of reasoning based on cases in intelligent decision support systems]. *Iskusstvennyy intellekt i prinyatiye resheniy* [Artificial intelligence and decision making], 2009, no.2, pp. 45-57.
20. Jackson P. *Vvedeniye v ekspertnyye sistemy* [Introduction to expert systems]. Moscow, Williams Publ., 2001, 623 p.
21. Aamodt A., Plaza E. Case-based reasoning: foundational issues, methodological variations, and system approaches. *AI Communications*, 1994, vol.7(1), pp. 39-59.
22. Kotlov Yu.V. *Modeli i algoritmy mnogokriterial`noy diagnostiki aviatsionnykh system* [Models and algorithms of multi-criteria diagnostics of aviation systems]. V sbornike: *Aktual`nyye problemy i perspektivy razvitiya grazhdanskoj aviatsii. Sbornik trudov XI Mezhdunarodnoy nauchno-prakticheskoy konferentsii* [In the collection: Current problems and prospects for the development of civil aviation. Proceedings of the XI International Scientific and Practical Conference]. Irkutsk, 2022, pp. 165-173.
23. Frankel D. *Model Driven Architecture: Applying MDA to Enterprise Computing*. New York: Wiley, 2003, 328 p.
24. Truyen F. *The Fast Guide to Model Driven Architecture: The Basics of Model Driven Architecture*. Cephas Consulting Corp, 2006, 12 p.
25. Eclipse Modeling Framework (EMF). Available at: <http://www.eclipse.org/modeling/emf/> (accessed: 11/20/2025).
26. Model-Integrated Computing (MIC). Available at: <http://www.isis.vanderbilt.edu/research/MIC> (accessed: 11/20/2025).
27. Yurin A.Yu. *Notatsiya dlya proektirovaniya baz znaniy produkcionnykh ekspertnykh sistem* [Notation for designing knowledge bases of rule-based expert systems]. *Ob`ektnyye sistemy* [Object systems]. 2016, vol.12, pp.48–54.
28. Stolbov A.B., Dorodnykh N.O., Nikolaichuk O.A. et al. *Generatsiya i transformatsiya spetsializirovannykh modeley dlya problemno-orientirovannogo intellektual`nogo pomoshchnika* [Generation and transformation of specialized models for a problem-oriented intellectual assistant]. V knige: *Lyapunovskiye chteniya 2023. Materialy 39-y mezhdunarodnoy konferentsii* [In the book: Lyapunov Readings 2023. Proceedings of the 39th International Conference]. Irkutsk, 2023, pp. 111-112.
29. Yurin A.Yu., Nikolaychuk O.A., Dorodnykh N.O. et al. *Using an Intelligent Assistant for Aircraft Diagnostics and Maintenance*. *Lecture Notes in Networks and Systems*, 2023, vol. 776, pp. 325-333, DOI:10.1007/978-3-031-43789-2\_30.
30. Gorbunov-Posadov M.M. *Rasshiryayemye programmy* [Expandable programs]. Moscow, Polyptykh Publ., 1999, 336 p.
31. Dorodnykh N.O., Nikolaichuk O.A., Kotlov Yu.V. et al. *Sozdaniye diagnosticheskikh sistem podderzhki prinyatiya resheniy s ispol`zovaniyem tablits resheniy* [Creation of diagnostic decision support systems using decision tables]. *Iskusstvennyy intellekt i prinyatiye resheniy* [Artificial intelligence and decision making], 2025, no.3, pp. 15-29.
32. Ereemeev A.P. *Produktsionnaya model` predstavleniya znaniy na baze yazyka tablits resheniy* [Production model of knowledge representation based on the language of decision tables]. *Izvestiya AN SSSR. Tekhnicheskaya kibernetika* [News of the USSR Academy of Sciences. Technical cybernetics], 1987, no.2, pp. 196-207.
33. Dorodnykh N.O., Nikolaichuk O.A., Yurin A.Y. *Ispol`zovaniye ontologicheskikh shablonov soderzhaniya pri postroyenii baz znaniy dlya tekhnicheskogo obsluzhivaniya i remonta aviatsionnoy tekhniki* [The use of ontological content templates in building knowledge bases for maintenance and repair of aviation equipment]. *Ontologiya proyektirovaniya* [Ontology of designing], 2022, vol.12, no.2, pp.158-171.
34. Personal Knowledge Base Designer. Available at: <http://www.knowledge-core.ru/index.php?p=pkbd> (accessed: 11/20/2025).
35. Knowledge Modeling System. Available at: <http://kms.knowledge-core.ru/> (accessed: 11/20/2025).
36. iDSS.Desktop. Available at: <http://www.knowledge-core.ru/index.php?p=idss> (accessed: 11/20/2025).
37. Visual builder for AI-powered bots. Aimylogic Available at: <https://aimylogic.com/> (accessed: 11/20/2025).
38. A convenient platform for creating and developing conversational AI solutions. Available at: <https://just-ai.com/platforma-jaicp> (accessed: 11/20/2025).
39. JAICP DSL. Available at: <https://help.cloud.just-ai.com/en/jaicp/dsl/> (accessed: 11/20/2025).
40. Dorodnykh N.O., Nikolaychuk O.A., Kotlov Yu.V. et al. *O podkhode k postroyeniyu baz znaniy dlya zadach aviatsionnoy diagnostiki* [On an approach to building knowledge bases for aviation diagnostic tasks]. *Izvestiya*

vysshikh uchebnykh zavedeniy. Aviatsionnaya tekhnika [Proceedings of higher educational institutions. Aviation Engineering], 2025, no. 1, pp. 131-139.

41. Perfiliev O.V., Ryzhakov S.G., Dolzhikov V.A. Ekspertnaya sistema analiza prichin neispravnostej dlya aviacionnoj tekhniki [Expert system for fault analysis of aviation equipment]. Izvestiya Samarskogo nauchnogo centra RAN [Proceedings of the Samara Scientific Center of the Russian Academy of Sciences], 2016, no. 18(4-3), pp. 564-570.
42. AviaTexPom.Assistent [AviaTekhPom.Assistant]. Available at: [https://www.altair-ii.ru/index.php?p=atp\\_assistant](https://www.altair-ii.ru/index.php?p=atp_assistant) (accessed: 11/20/2025).
43. Berman A.F. Degradatsiya mekhanicheskikh system [Degradation of mechanical systems]. Novosibirsk, Nauka Publ., 1998, 320 p.

**Dorodnykh Nikita Olegovich.** Ph.D., senior associate researcher at Matrosov Institute for System Dynamics and Control Theory SB RAS (ISDCT SB RAS). Main research domains: computer-aided development of intelligent systems and knowledge bases, knowledge acquisition based on documents, tables and conceptual models, semantic table interpretation. SPIN: 1922-2224, ORCID: 0000-0001-7794-4462; Author ID (RSCI): 979843; Author ID (Scopus): 57202323578; Researcher ID (WoS): E-8870-2014. [nikidorny@icc.ru](mailto:nikidorny@icc.ru).

**Stolbov Aleksandr Borisovich.** Ph.D., researcher at ISDCT SB RAS, associate professor at the Institute of Information Technology and Data Analysis of INRTU. Main research areas: system analysis, mathematical and simulation modeling of multicomponent systems, development of virtual assistants. SPIN: 9524-6300, ORCID: 0000-0001-6513-7030; Author ID (RSCI): 185900; Author ID (Scopus): 57119776700; Researcher ID (WoS): A-6478-2014. [stolboff@icc.ru](mailto:stolboff@icc.ru).

**Yurin Aleksandr Yurievich.** Doctor of sciences, a head of a laboratory "Information and telecommunication technologies for investigation of technogenic safety" at ISDCT SB RAS, professor of INRTU, a leading researcher at the Irkutsk branch of MSTU CA. Main research domains: development of intelligent systems and knowledge bases, application of the case-based reasoning and semantic technologies in the design of diagnostic intelligent systems, maintenance of reliability and safety of complex technical systems. SPIN: 5830-7930, ORCID: 0000-0001-9089-5730; Author ID (RSCI): 174845; Author ID (Scopus): 16311168300; Researcher ID (WoS): A-4355-2014. [iskander@icc.ru](mailto:iskander@icc.ru).

Статья поступила в редакцию 13.11.2025; одобрена после рецензирования 07.12.2025; принята к публикации 25.05.2026.

The article was submitted 11/13/2025; approved after reviewing 12/07/2025; accepted for publication 05/25/2026.

## Инструменты мониторинга данных устройств интернета вещей

Камышев Никита Львович, Исаева Ольга Сергеевна

Институт вычислительного моделирования СО РАН,  
Россия, Красноярск, [nik.novov@gmail.com](mailto:nik.novov@gmail.com)

**Аннотация.** В статье представлено решение задачи создания автономной системы мониторинга микроклимата технических помещений, способной к оперативному выявлению аномалий в условиях нестационарных данных и ограниченной сенсорной инфраструктуры. Цель исследования – разработка инструментов мониторинга, которые бы обеспечили непрерывный контроль, детекцию аномалий и их интерпретацию. Основное содержание работы включает разработку функциональной модели системы, реализацию модулей сбора телеметрии и гетерогенного хранения данных, а также внедрение оригинального гибридного алгоритма анализа временных рядов. Ключевым элементом стал предложенный метод, сочетающий спектральный анализ для выделения периодических компонентов сигнала и адаптивные статистические пороги, динамически рассчитываемые на основе скользящих исторических окон. В отличие от существующих аналогов, опирающихся на ресурсоемкое глубокое обучение, предложенный подход использует физически обоснованные признаки для адаптации к сезонной вариативности данных без этапа предварительного обучения на размеченных датасетах. Для унификации подхода к обнаружению аномалий и маршрутизации оповещений настроены специальные правила оповещения, выполнена интеграция с системой визуализации данных и создан чат-бот, выполняющий уведомления и запросы. Для повышения отказоустойчивости внедрён механизм контроля живучести компонентов. Научная новизна работы заключается в предложении гибридного адаптивного метода детекции аномалий, базирующегося на спектрально-статистическом анализе временных рядов. Предложенный подход обеспечивает интерпретируемость результатов, раскрывая физическую природу сбоев через декомпозицию сигнала на гармонические составляющие. Результаты верификации на реальном массиве данных объёмом 5,3 млн записей подтвердили эффективность подхода: полнота детекции составила 0,991 при точности 0,877. Нагрузочное тестирование продемонстрировало устойчивость архитектуры при низкой утилизации ресурсов процессора (<6%) и наличие резерва для масштабирования. Опытная эксплуатация позволила выявить инциденты, связанные с отказом системы кондиционирования. Разработанная система обеспечивает полный цикл от сбора данных до превентивного оповещения, предоставляя понятные инструменты диагностики для предотвращения аварийных ситуаций, поддерживая два уровня взаимодействия: упрощённый интерфейс для конечных пользователей и расширенные аналитические функции для специалистов.

**Ключевые слова:** Интернет вещей, мониторинг микроклимата, обнаружение аномалий, спектральный анализ, адаптивные пороги, отказоустойчивость, Prometheus, AlertManager

**Цитирование:** Камышев Н.Л. Инструменты мониторинга данных устройств интернета вещей / Н.Л. Камышев, О.С. Исаева // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 206-219. – DOI:10.25729/ESI.2026.42.2.016.

**Введение.** За последние годы технологии Интернета вещей (Internet of Things, IoT) прочно вошли в научные и промышленные приложения, обеспечивая возможность непрерывного сбора, передачи, хранения и анализа данных в реальном времени [1]. IoT-устройства играют ключевую роль в автоматизации и оптимизации технологических процессов и находят широкое применение в таких областях, как умные дома, промышленное производство, здравоохранение, сельское хозяйство и др. [2]. Современные исследования в этой сфере сосредоточены на решении задач, связанных с обеспечением безопасного межмашинного взаимодействия, повышением отказоустойчивости систем, адаптацией к динамически изменяющимся условиям эксплуатации, оптимальным размещением сенсоров, а также разработкой методов и инструментов для анализа больших объёмов данных, генерируемых распределёнными устройствами [3].

В Институте вычислительного моделирования СО РАН ведутся работы по созданию специализированной системы мониторинга микроклимата технологических помещений, в

которых размещается телекоммуникационное оборудование. Такое оборудование характеризуется высоким уровнем тепловыделения и строгими требованиями к параметрам окружающей среды (температура, влажность, PM2.5), поскольку их отклонение от нормативных значений может привести к снижению надёжности или полному отказу аппаратуры. В рамках проекта разработана распределённая IoT-инфраструктура [4] на основе протокола MQTT, объединяющая сенсорные узлы, агенты сбора данных, серверные компоненты и программное обеспечение, совместимое с различными IoT-платформами для решения прикладных задач. Используемая система не включает инструментов автоматического выявления аномалий в данных.

Существующие решения для мониторинга микроклимата могут быть реализованы либо на основе универсальных платформ, либо с использованием специализированных программных систем. К числу широко распространённых IoT-платформ относятся ThingSpeak, AWS IoT Core, Google Cloud IoT Core и IBM Watson IoT [5]. Они предоставляют гибкие инструменты для подключения устройств, управления данными, визуализации и базовой аналитики. Однако при применении в задачах критического мониторинга такие платформы демонстрируют высокую зависимость от облачной инфраструктуры, ограниченные возможности локальной обработки данных, повышенные требования к вычислительным ресурсам, а также необходимость существенной доработки и адаптации к специфике предметной области. Специализированные исследовательские и коммерческие системы [6] опираются на глубокую интеграцию с характеристиками предметной области для повышения качества результатов. Например, в работе [7] представлена система управления знаниями IoT-CANE с многоуровневой архитектурой для обработки больших данных. Прототипы на базе микроконтроллеров демонстрируют высокую точность измерений при низкой стоимости [8]. Для создания программных комплексов интеллектуальных зданий применяются структурные и поведенческие шаблоны, позволяющие обеспечивать устойчивость взаимодействия компонентов и реализовывать различные сценарии управления климатом [9]. Однако представленные архитектурные подходы в большей мере направлены на сбор и визуализацию данных и требуют значительной доработки для интеграции со специализированными алгоритмами анализа временных рядов.

В последние годы значительное число исследований посвящено применению методов машинного обучения для мониторинга технического состояния оборудования. Наблюдается переход от традиционных стратегий к адаптивно-прогнозным системам управления, которые интегрируют модели прогнозирования с механизмами адаптации к неопределённостям [10]. Для повышения эффективности комбинируют эти подходы с методами глубокого обучения, способными в режиме онлайн корректировать параметры модели на основе поступающих данных с сенсоров в условиях высокой стохастичности среды. Активно развиваются подходы на основе автоэнкодеров и рекуррентных нейронных сетей (LSTM, GRU), позволяющие выявлять сложные нелинейные зависимости и аномалии в многомерных временных рядах IoT-сенсоров. Пример развития данного направления можно найти в работе [11]. Авторами проведено сравнение эффективности различных архитектур автоэнкодеров и показано, что использование ячеек LSTM внутри автоэнкодера позволяет модели запоминать долгосрочные зависимости в траектории изменения температуры и детектировать отклонения раньше, по сравнению с классическими (RNN) и полносвязными (DNN) сетями. Однако авторы отмечают, что достижение такого преимущества требует тщательной настройки гиперпараметров (количество слоёв, функция потерь) и процедуры нормализации данных для предотвращения переобучения, а порог срабатывания определяется статистически на основе максимальной ошибки реконструкции. Аналогичные результаты получены и для других областей: так, в

работе [12] гибридные модели успешно применялись для детекции неисправностей ветрогенераторов на основе вибрационных данных после сложной предобработки.

Несмотря на высокую точность, подходы на базе глубокого обучения имеют ограничения для задач оперативного мониторинга. Несмотря на превосходство моделей глубокого обучения в точности детекции аномалий по сравнению с традиционными методами, их внедрение в промышленную эксплуатацию ограничено эффектом «черного ящика» [13]. Такие модели без методов объяснимого искусственного интеллекта не предоставляют понятных причин срабатывания систем оповещения. Для эффективного принятия решений, кроме выявления аномалии, необходимо понимать, является ли она, например, изменением суточного цикла, выходом из строя элементов системы оповещения или единичным выбросом. Кроме того, обучение и применение нейросетевых моделей требуют значительных вычислительных мощностей и энергопотребления. Модели требуют больших объёмов размеченных или тщательно отфильтрованных данных для обучения, чтобы избежать переобучения на артефактах или случайных отклонениях в данных.

Целью работы является создание автономной IoT-системы, способной обеспечивать непрерывный контроль параметров микроклимата в технических помещениях и выявлять аномалии для снижения рисков выхода из строя чувствительного оборудования. В отличие от решений, опирающихся на сложные архитектуры глубокого обучения, используется гибридный метод, сочетающий спектральный анализ и адаптивные статистические пороги. Данный подход близок к современным методам интерпретируемой диагностики, основанным на извлечении физически обоснованных статистических признаков [14]. Такая стратегия позволяет преодолеть ограничения «черного ящика», свойственные глубоким нейросетям, и обеспечивает детектирование периодических нарушений с высокой интерпретируемостью логики принятия решений.

**1. Выбор инструментов для реализации системы мониторинга.** При выборе системы управления базами данных для хранения информации с IoT-устройств были проанализированы как специализированные решения, ориентированные на хранение и обработку временных рядов (TSDB), так и универсальные системы классов NoSQL и SQL. В Таблице 1 представлены результаты сравнения по совокупности критериев, необходимых для задач непрерывного сбора, хранения и анализа временных рядов.

На основе анализа характеристик, представленных производителями и аналитическим ресурсом DB-Engines, а также по результатам нагрузочного тестирования, были выделены ключевые параметры производительности и ресурсной эффективности. В качестве сценария тестирования использовалась последовательная пакетная запись данных в соответствии со структурой полей датчика CL210-E без предварительного создания индексов.

**Таблица 1.** Сравнительный анализ систем управления базами данных

Параметры	MongoDB	InfluxDB	PostgreSQL	ClickHouse
Тип базы данных	Документо-ориентированная NoSQL	Временных рядов	Реляционная SQL	Колоночная, ориентированная на аналитику
Хранение временных рядов	Требует настройки	Изначально хранит так	Создание временных таблиц	Имеется
Совместимость с SQL	PromQL	Limited SQL	SQL	Full SQL и собственные конструкции

Индексация	Динамическая индексация полей	Индексация по тегам и временным меткам	Глобальная индексация	Специальные индексы для колоночной структуры
Оптимальное использование	Хранилище произвольных данных	Сбор метрик и мониторинг	Анализ исторических данных	Большие данные
Горизонтальное масштабирование	Ограничено (есть шардирование)	Среднее	Шардирование	Имеется
Производительность	Высокая	Высокая для временных данных	Высокая	Исключительно быстрая для OLAP
Объем памяти на 1000 данных	14.35 КБ	19.5 КБ	17.32 КБ	9.8 КБ

Сравнительный анализ показал преимущества систем MongoDB и PostgreSQL в контексте поставленных задач. Итоговая оценка проводилась по результатам измерения скорости записи и объема дискового пространства (рис. 1). При достижении объема в 10 млн записей явное преимущество по экономичности хранения показала MongoDB 143.47 МБ, в отличие от PostgreSQL, объем которой составил 173.18 МБ (на 20.7% больше).




Рис. 1. Результаты тестов БД

Определяющими критериями стали гибкость документно-ориентированной модели данных, позволяющая эффективно хранить разнородные сведения, поступающие от различных IoT-устройств, а также встроенная поддержка временных рядов [15]. Их использование обеспечивает автоматическую оптимизацию хранения и индексацию по временным меткам, что существенно упрощает обработку динамических данных. Кроме того, система имеет поддержку языка Python и широкую интеграцию с популярными инструментами визуализации, такими, как Grafana и Tableau. По эффективности хранения MongoDB уступает специализированным решениям, таким, как InfluxDB и ClickHouse, но её способность поддерживать гибридные сценарии, предполагающие одновременное хранение как структурированных метрик, так и метаданных устройств, делает её практичным выбором для решения поставленной задачи.

Для реализации модуля анализа и визуализации собранных телеметрических данных был проведен сравнительный анализ популярных решений: Prometheus, Grafana Cloud, Graphite и Graylog. Оценка инструментов осуществлялась по комплексу критериев, включающих архитектурную автономность, нативную поддержку временных рядов, механизмы сбора

данных (Pull/Push), функциональность подсистем оповещения и степень совместимости с выбранной СУБД MongoDB. По результатам анализа в качестве основного инструмента мониторинга был выбран Prometheus. Его преимущества – это архитектурная автономность и специализация на работе с временными рядами. Prometheus представляет собой самодостаточную систему, включающую компоненты для сбора метрик, хранения данных (встроенная TSDB), обработки запросов и генерации оповещений (через Alertmanager). Возможность размещения в изолированных сетевых средах делает его одним из наиболее подходящих решений для промышленных и корпоративных приложений с повышенными требованиями к информационной безопасности.

## 2. Проектирование инструментов мониторинга данных устройств интернета вещей

**2.1. Функциональная модель.** Для обеспечения системного подхода к проектированию была разработана функциональная модель в нотации IDEF0. В соответствии с выбранной нотацией процессы описаны в виде иерархических диаграмм, где каждая функция включает следующие компоненты: входы, выходы, контролирующие факторы и механизмы (рис. 2).



Рис. 2. Контекстная диаграмма модели в нотации IDEF0

Целевой функцией верхнего уровня модели является формирование оповещений о критических отклонениях параметров микроклимата. Модель обеспечивает модульность архитектуры, способствует комплексной реализации необходимых функций и упрощает анализ взаимодействия между компонентами системы. На основе модели выполнена формализация подсистем и верификация их поведения.

Формальное описание модели:  $F = \{A_1, A_2, A_3, A_4\}$  – множество ключевых функций системы, где каждая функция  $A_i$  описывается кортежем:  $A_i = \langle I_i, O_i, C_i, M_i \rangle$ , где  $I_i$ : входы,  $O_i$  – выходы, представляющие результаты обработки, объекты,  $C_i$  – контролирующие факторы, ограничения, правила, нормативные требования, конфигурации,  $M_i$  – механизмы, представляющие собой программные и аппаратные средства реализации. Далее приведено описание функции  $A_i$ .

**2.2. Получение данных ( $A_1$ ).** Функция предназначена для сбора данных в реальном времени от сенсорных устройств через протокол MQTT, а также от внешних источников через API (публичные метеоданные). Реализация выполнена в виде клиентского приложения на

языке Python, поддерживающего параллельную обработку потоков. Данные поступают в реальном времени через подписки на темы  $T = \{t_1, \dots, t_7\}$ , ассоциированные с собираемыми показателями (температура, влажность и др.), и преобразуются в JSON-формат для дальнейшей обработки. Используются настройки MQTT (конфигурация брокера Mosquitto) и ключи API для аутентификации.

В кортеж  $A_1$  входят:  $I_1 = \{D_{MQTT}, D_{API}\}$  – потоки данных от датчиков и внешних API,  $O_1 = D'$  – объединённые данные в формате JSON,  $C_1 = \{MQTT_{conf}, API_{keys}\}$  – настройки протокола и ключи доступа,  $M_1 = \{Python_{API}\}$  – клиент сбора данных на Python.

Функция обеспечивает параллельное отображение  $pl: S \rightarrow X$ , где  $S = \{s_1, s_2, \dots, s_n\}$  – множество датчиков ( $n$ ), генерирующее временной ряд  $X = \{x_{ij} \mid i = 1 \dots n, j = 1 \dots m\}$ ,  $m$  – множество параметров,  $x_{ij} = \langle temp_t, hum, dew_p, s_t, pm2.5, \dots \rangle$  – кортеж значений (температуры, влажности, точки росы, состояния датчика, показателей мелкодисперсной пыли и другие). Доступ к темам задаётся подпиской  $sub: T \rightarrow X$ , где  $T = \{t_1, \dots, t_m\}$ , с параллельной обработкой для минимизации задержек.

**2.3. Сохранение метрик ( $A_2$ ).** Функция отвечает за долговременное хранение и временное буферирование данных. Реализация выполнена через интеграцию с системами Prometheus (для оперативного мониторинга) и MongoDB (для долгосрочного хранения).

В Python-приложении создаются классы для каждого датчика, содержащие временные буферы объёмом до 20 элементов. Эти буферы используются для локального анализа и формирования агрегированных метрик. Prometheus собирает метрики приложения. Интервал сбора  $\Delta_s = 10s$  в соответствии с конфигурационным файлом `prometheus.yml`. Одновременно данные записываются в коллекции MongoDB.

Кортеж  $A_2$  состоит из  $I_2 = X'$  – нормализованные входные данные,  $O_2 = Met \cup \{W_i\}$  – набор метрик и временные буферы,  $C_2 = \{prometheus.yml, K_i\}$  – конфигурация сбора и параметры классов (размер буфера, частота обновления),  $M_2 = \{MongoDB, Prometheus\}$  – используемые программные механизмы.

Функция импорта данных определяется как:  $imp: X' \rightarrow Met$ , где  $Met = \{m_k(t)\}$ . Каждый класс  $K_i$  задаётся кортежем:  $K_i = \langle buffer_i, limit = 20 \rangle$ , где  $buffer_i = \{x_{ij}(t - limit), \dots, x_{ij}(t)\}$  – скользящее окно измерений, обновляемое операцией  $update(K_i, x_{ij})$ . Конфигурация:  $C_2 = \{global, scrape_configs, ports, K_i(limit)\}$ , где  $global = \{\Delta_s = 10s, \Delta_e = 10s\}$ , применяется с помощью операции  $apply: C_2 \rightarrow Prometheus$ .

**2.4. Анализ и проверка ( $A_3$ ).** Функция реализует механизмы обнаружения аномалий в потоке данных, сочетая классические статистические подходы и алгоритмический анализ временных рядов. Выбор методов обусловлен спецификой IoT-данных [15-16]. Анализ включает использование: квантильного коридора, пороговое сравнение на основе статистических границ и спектральный анализ.

Метрики, сформированные в  $A_2$ , периодически (с интервалом  $\Delta_s = 10s$ ) поступают в Prometheus, где с помощью правил проверяются условия срабатывания оповещений. При выполнении одного из условий формируется событие, которое передаётся на следующий этап для маршрутизации. Кортеж функции  $A_3$  описывается следующими элементами:  $I_3 = Met \cup \{W_i\}$  – входные метрики и временные буферы,  $O_3 = A$  – множество обнаруженных аномалий,  $C_3 = \{alert_rules.yml\}$  – правила оповещения,  $M_3 = \{Alertmanager, Quantile, Threshold, FFT\}$  – механизмы анализа и реагирования. Для каждого момента времени  $t_i$  формируется скользящее окно:  $W_i = \{x_{kj} \mid t_k \in [t_i - \Delta t, t_k], k = i - max_i, \dots, i\}$ , содержащее  $max_i$  значений

$x_{kj}$ . В методе  $Threshold \in M_3$  используются фиксированные границы  $x_{min}$  и  $x_{max}$ , на основе длительного периода наблюдений и нормативных требований к микроклимату технических помещений. Значение  $x_{ij}$  – аномальное,  $x_{ij} < x_{min}$  или  $x_{ij} > x_{max}$ .

Для выявления отклонений в потоке данных применяется квантильный метод  $Quantile \in M_3$ . Для каждого скользящего окна вычисляются эмпирические квантили  $q_{0.05}(W_i)$  и  $q_{0.95}(W_i)$ . Практическая апробация показала, что статические заданные границы не способны адаптироваться к суточным и сезонным изменениям параметров среды.

Выбор уровней квантилей 0.05 и 0.95 обусловлен результатами анализа плотности распределения исторических данных (рис. 3).




Рис. 3. Статические пороги  $q_{0.01}/q_{0.99}$  и  $q_{0.05}/q_{0.95}$

Выявлено, что при использовании порогов ( $q_{0.01}/q_{0.99}$ ) система игнорирует существенные, но кратковременные нарушения суточного цикла. При расширении интервала до  $q_{0.10}/q_{0.90}$  увеличивается количество ложных срабатываний. Точка  $x_{ij}$  классифицируется как аномалия, если  $x_{ij} < q_{0.05}(W_i)$  или  $x_{ij} > q_{0.95}(W_i)$ .

Спектральный метод  $FFT \in M_3$  заключается в применении к скользящему окну  $W_i$  быстрого преобразования Фурье  $F(W_i) = FFT(\{x_{kj}\}_{k: t_k \in [t_i - max_i, t_i]})$ . Обоснование параметров метода выполнено на основе ретроспективного анализа 3,1 млн наблюдений (2024–2025 гг.), выявившего устойчивую двухчастотную структуру сигнала: низкочастотный компонент (суточный цикл, ~24 ч) и высокочастотный (цикл климат-контроля, 5.6–7.1 мин). Статистический анализ подтвердил значительную сезонную вариативность энергетического вклада суточной гармоник (разброс >14%: от 18.6% зимой до 32.6% летом) и нестабильность периода работы оборудования, что исключает использование фиксированных порогов.

Вариативность энергетического профиля и нестабильность периодов работы оборудования обосновывают необходимость внедрения адаптивного подхода к формированию границ нормы спектра. Пороговые значения  $\eta_f$  для каждой частоты  $f_k$  определяются динамически, как 95-й процентиль распределения амплитуд:  $\eta_f(t_i) = q_{0.95}(\{|F(W_j)(f_k)|\}_{j=i-N}^{i-1})$  накопленного эталонного спектра, сформированного из исторического буфера длиной  $N$  предыдущих скользящих окон. Размеры скользящих окон определены с учётом выявленной периодичности: малое окно ( $N_1 = 120$  отсчетов, ~20 мин) для фиксации резких изменений и расширенное окно ( $N_2 = 540$  отсчетов, ~90 мин) для статистически устойчивой оценки гармоник без эффекта спектрального размывания.

Точка  $x_{ij}$  считается аномальной, если амплитуда на частоте  $f_k$  превышает заданный порог:  $|F(W_i)(f_k)| > A_k$ , где  $A_k$  – пороговое значение для частоты  $f_k$ . Физически это соответствует резкому количественному доминированию конкретных гармоник над эталонным профилем, сформированным в предыдущие периоды наблюдения, что интерпретируется как появление неперiodического скачка или нарушение циклического режима работы оборудования, отличного от обычных процессов.

**2.5. Интерфейс в Telegram (A<sub>4</sub>).** Функция реализует канал взаимодействия с пользователем через мессенджер Telegram. Разработан бот на основе Telegram Bot API, интегрированный с Alertmanager. Бот позволяет выполнять отправку push-уведомлений при обнаружении аномалий и обработку пользовательских запросов (например, команда /info для получения графика за заданный период). Alertmanager настроен для маршрутизации событий с использованием токена бота и идентификатора чата. Инструменты визуализации выполнены в Python и передаются в чат в виде изображений.

Кортеж функции  $A_4$  представляет:  $I_4 = A \cup Ev$  – аномалии и события,  $O_4 = Resp$  – уведомления и графики,  $C_4 = \{bot\_token, alert\_rules.yml\}$  – конфигурационные параметры,  $M_4 = \{AlertManager, TelegramAPI\}$  – программные механизмы для выполнения правил и взаимодействия с пользователем. Обработка запросов формализуется функцией:  $proc: Ev \cup Req \rightarrow Resp$ , где  $Req = \{A_u = \langle type_u, period_u \rangle$  – множество пользовательских запросов. Графики формируются, как:  $plot: Met_{A_u(periode)} \rightarrow Image$ , а уведомления, как:  $push: Req \rightarrow Msg$ , в соответствии с правилами с правилами  $C_4(Req)$ .

**3. Механизм контроля живучести системы.** Для обеспечения надёжности работы реализован механизм контроля живучести компонентов в реальном времени – HeartBeat. Он выполняет генерацию запросов с периодической проверкой активности IoT-датчиков и других узлов инфраструктуры на основе заданных в Prometheus метрик.

Рассмотрим  $H = \{h_1, h_2, \dots, h_n\}$  – множество компонентов системы (включая датчики). Состояние каждого компонента определяется как:  $state(h_k) \in \{active, in\_active\}$ . Механизм контроля реализован через alert\_rules.yml. Пример правила приведён на Рис. 4.

```

- alert: Heartbeat_000DE0163B57
  expr: >
  (1) absent_over_time(mqtt_000DE0163B57_temperature_c[5m])
  (2) and
  (time() - process_start_time_seconds{job="prometheus"} > 600)
  (3) for: 2m
  (4) labels:
      severity: critical
      sensor_id: 000DE0163B57
  annotations:
      summary: "Нет данных от датчика 000DE0163B57"
      description: |
        **Статус:** Не отвечает более 5 минут,
        **Датчик:** 000DE0163B57

```

**Рис. 4.** Пример правила HeartBeat для IoT-датчика

Правило включает следующие элементы (см. рис. 4): (1) – проверка отсутствия метрики температуры в течение 5 минут, (2) – исключение ложных срабатываний в первые 10 минут после запуска Prometheus, (3) – задержка активации оповещения на 2 минуты для фильтрации кратковременных перебоев, (4) – метки для классификации и группировки правил.

Интервал проверки в 5 минут выбран на основе расчета максимальной скорости изменения данных в ситуации, где пиковое отклонение не превышает критическое значение безопасности. Таким образом, он обеспечивает гарантированное обнаружение выхода датчика из строя до момента наступления неконтролируемого перегрева.

Генерация запросов формализуется, как функция:  $gen: H \times \Delta t \rightarrow Q$ , где  $Q = \{q_m = \langle sender_m, receiver_m, timestamp_m, type_m \rangle\}$  – множество служебных запросов,  $sender_m$  – узел Prometheus,  $receiver_m = h_{000DE0163B57}$  – целевой датчик,  $timestamp_m$  – время отправки,  $type_m = status$  – запрос статуса, а периодичность  $\Delta t$  синхронизирована с интервалом сбора метрик в Prometheus. Операция проверки определяется, как:

$$check(h_{000DE0163B57}) = \begin{cases} 1, & \text{если } mqtt_{000DE0163B57_{t_c}} \neq \emptyset \\ 0, & \text{если } mqtt_{000DE0163B57_{t_c}} = \emptyset \end{cases}$$

где условие означает, что метрика  $mqtt_{000DE0163B57_{t_c}}$  присутствует в окне  $[t - 5m, t]$ . При отсутствии метрики устанавливается  $state(h_{000DE0163B57}) = inactive$ , и генерируется аномалия  $a_h$ , которая инициирует оповещение пользователя.

**4. Внедрение инструментов мониторинга данных IoT-устройств.** Созданная система оповещения на основе данных IoT-устройств обеспечивает непрерывный мониторинг и анализ параметров микроклимата в реальном времени, а также своевременное выявление аномалий и информирование пользователей. Первая версия системы была развёрнута на облачной платформе, функционирует в штатном режиме и предназначена для последующей замены обновлённой реализацией. Тестирование обновлённой системы проводилось в рамках исследовательской IoT-среды [17], включающей четыре сенсорных устройства CL210-E, интегрированных через протокол MQTT.

Для оценки эксплуатационных характеристик был проведен мониторинг ресурсов, показавший, что средняя нагрузка на CPU составила 5,94%, а объем занимаемой оперативной памяти (RAM) стабилизировался на отметке 1014,74 МБ. Данные показатели подтверждают стабильность работы системы при интенсивной обработке потоков телеметрии и выполнении аналитических процедур в реальном времени. Динамика потребления ресурсов представлена на рисунке 5.

CPU %	MEM USAGE / LIMIT	MEM %	NET I/O	BLOCK I/O
0.21%	157.5MiB / 15.52GiB	0.99%	42.9MB / 48.8MB	82.1MB / 0B
1.84%	135.1MiB / 15.52GiB	0.85%	101MB / 239MB	135MB / 0B
0.56%	104.3MiB / 15.52GiB	0.66%	20.6MB / 553MB	561MB / 160MB
0.02%	181.9MiB / 15.52GiB	1.14%	8.64kB / 21.6kB	130MB / 8.51MB
0.66%	164.5MiB / 15.52GiB	1.04%	52MB / 46.4MB	7.8GB / 2.34GB
4.66%	193MiB / 15.52GiB	1.21%	52.3MB / 26.8MB	17.4MB / 4.58MB
0.36%	22.54MiB / 15.52GiB	0.14%	14.4MB / 161MB	142MB / 582kB
1.23%	61.8MiB / 15.52GiB	0.39%	841MB / 54.4MB	1.47GB / 1.29GB

Рис. 5. Использование CPU, RAM

Расчётные затраты дискового пространства на поддержание базы данных при достижении объёма в 10 млн записей составляет 143.46 МБ. При интенсивности поступления данных порядка 34 560 пакетов в сутки, текущая конфигурация хранилища обеспечивает автономную работу системы в течении года без необходимости архивации данных. При этом низкая загрузка CPU и стабильный объём RAM свидетельствуют о наличии вычислительного резерва для дальнейшего масштабирования системы.

Функционирование модуля  $A_1$  обеспечивает сбор данных и формирование временного ряда:  $X = \{x_{ij} \mid i = 1 \dots 4, j = 1 \dots 7\}$ , где  $i$  – индекс датчика,  $j$  – индекс измеряемого параметра. Функции модуля  $A_2$  сохраняют метрики в базе данных MongoDB и в локальных буферах объёмом 120 и 540 значений для каждого параметра. За период тестирования было накоплено 5,3 млн записей общим объёмом 191,9 МБ.

Для верификации разработанного алгоритма было проведено сравнение автоматически выявленных аномалий с эталонной разметкой, выполненной экспертами на ретроспективных данных за 2024–2025 годы, которая составила 1370 эталонных событий. Анализ метрик качества: Precision (точность) = 0.877, Recall (полнота) = 0.991, F1-Score = 0.930 показал

способность метода детектировать практически все значимые сбои. Наличие 12 ложноотрицательных срабатываний объясняется различием в условиях анализа: эксперт при ретроспективной разметке обладает полным контекстом развития события во времени, тогда как алгоритм работает в режиме онлайн и фиксирует аномалию только по факту проявления явных признаков отклонения, что может приводить к небольшой задержке детекции на начальных стадиях развития инцидента. Снижение точности обусловлено наличием 182 ложноположительных срабатываний. На рисунке 6 приведён фрагмент временного ряда температуры и области, показывающие результаты классификации событий (истинно положительные срабатывания, совпадающие с разметкой, и ложно положительные, когда программа выдаёт сигнал об аномалии при отсутствии сбоя по мнению эксперта).




Рис. 6. Сравнение диагностики и экспертной разметки

Детальный анализ показал: ложноположительные результаты соответствуют нарушениям цикличности работы оборудования, которые не приводят к немедленному выходу параметров за аварийные пределы, но сигнализируют о нестабильности режима и требуют превентивного контроля, что в полной мере подходит для систем мониторинга.

Дополнительно применимость метода была подтверждена в ходе опытной эксплуатации системы мониторинга. За период внедрения было выявлено и верифицировано 11 реальных инцидентов, корректно классифицированных алгоритмом. Среди диагностированных неисправностей: отказы и разбалансировка работы кондиционирующих систем, обмерзание теплообменников внутренних блоков, а также дефекты датчиков. При обнаружении аномалий выполняется генерация оповещений на основе правил в Prometheus. Если условие сохраняется в течение 5 минут, событие передаётся в Alertmanager, который отправляет уведомление в настроенный Telegram-бот. Система реализует повторные оповещения по одному и тому же событию с периодичностью раз в 20 минут, при условии, что аномалия сохраняется дольше 5 минут. Для детального анализа данных выполняется подключение к инструментам визуализации Grafana.

**Заключение.** В работе реализован и верифицирован полный цикл создания автономной IoT-системы мониторинга микроклимата, охватывающий этапы от сбора телеметрии до формирования физически интерпретируемых оповещений о критических отклонениях. Разработанная архитектура обеспечивает модульное взаимодействие разнородных компонентов (сенсоры CL210-E, брокер Mosquitto, СУБД MongoDB, система мониторинга Prometheus) и поддерживает многоуровневый интерфейс взаимодействия: от автоматизированных push-уведомлений в Telegram до углубленного анализа через Grafana. Нагрузочное тестирование при обработке потока данных интенсивностью 34 560 пакетов в сутки и накоплении массива свыше 5,3 млн записей подтвердило стабильность работы системы и наличие значительного вычислительного резерва для дальнейшего масштабирования.

Ключевым результатом работы стало решение проблемы детекции аномалий в условиях выраженной нестационарности данных микроклимата. В отличие от статических пороговых методов и сложных моделей «черного ящика», в системе реализован гибридный подход, сочетающий спектральный анализ и адаптивные статистические коридоры. Предложенный механизм адаптации, основанный на динамическом пересчёте пороговых значений на основе амплитуд в скользящем историческом буфере, позволил автоматически подстраивать чувствительность системы под текущий режим эксплуатации, эффективно отсекая ложные срабатывания на штатные сезонные колебания. Опытная эксплуатация системы подтвердила её практическую ценность: за период тестирования были выявлены и верифицированы инциденты, связанные с отказом системы кондиционирования, их обмерзанием и дефектами датчиков. Созданная система представляет собой готовое к внедрению решение, способное функционировать в автономном режиме, адаптироваться к изменяющимся условиям среды и предоставлять персоналу прозрачные инструменты диагностики для предотвращения аварийных ситуаций.

**Благодарности.** Работа поддержана Красноярским математическим центром, финансируемым Минобрнауки РФ в рамках мероприятий по созданию и развитию региональных НОМЦ (Соглашение 075-02-2026-735).

#### Список источников

1. Довгаль В.А. Интернет Вещей: концепция, приложения и задачи / В.А. Довгаль, Д.В. Довгаль // Вестник Адыгейского государственного университета. Сер. Естественно-математические и технические науки, 2017. – № 4(211). – С. 140–147.
2. Kumar S., Tiwari P., Zymbler M. Internet of Things is a revolutionary approach for future technology enhancement: a review. *Journal of Big Data*, 2019, no. 6, p. 111, DOI: 10.1186/s40537-019-0268-2.
3. Исаева О.С. Формирование адаптивных рассылок брокера данных интернета вещей / О.С. Исаева, Н.В. Кулясов, С.В. Исаев // Информационно-управляющие системы, 2022. – № 5 (120). – С. 23-31. – DOI: 10.31799/1684-8853-2022-5-23-31.
4. Исаева О.С. Создание инструментов сбора данных для анализа аспектов безопасности Интернета вещей / О.С. Исаева, Н.В. Кулясов, С.В. Исаев // Информационные и математические технологии в науке и управлении. – 2022. – № 3(27). – С. 113-125. – DOI:10.38028/ESI.2022.27.3.011
5. Saputri F.R., Linelson R., Salehuddin M. et al. Design and development of an irrigation monitoring and control system based on blynk internet of things and thingspeak. *PLoS ONE*, 2025, vol. 20, no. 4, pp. 1-19, DOI:10.1371/journal.pone.0321250.
6. Spandonidis C., Tsantilas S., Sedikos E. et al. A compact, modular and low-cost Internet of Things (IoT) platform for air quality monitoring in urban areas. *Journal of Physics: Conference Series*, 2020, vol. 1710, no. 1, p. 012004, DOI:10.1088/1742-6596/1710/1/012004.
7. Yin hao L., Alqahtani A., Solaiman E. et al. IoT-CANE: A unified knowledge management system for data-centric Internet of Things application systems. *Journal of Parallel and Distributed Computing*, 2019, no. 131, pp. 161-172, DOI: 10.1016/j.jpdc.2019.04.016.
8. Табиев С. IoT технологии в системах мониторинга микроклимата помещений // С. Табиев, А. Орынбай // Вестник КазАТК, 2024. – № 136(1). – С. 299-307, DOI: 10.52167/1609-1817-2025-136-1-299-307.
9. Кычкин А.В. Разработка программной системы для управления IoT-устройствами с использованием структурных и поведенческих паттернов / А.В. Кычкин, О.В. Горшков // Прикладная информатика, 2020. – Т. 15. – № 4. – С. 35–44.
10. Gholamzadehmir M., Del Pero C., Buffa S. et al. Adaptive-predictive control strategy for HVAC systems in smart buildings – a review. *Sustainable Cities and Society*, 2020, vol. 63, p. 102480, DOI: 10.1016/j.scs.2020.102480.
11. Qais M.H., Kewat S., Loo K.H. et al. LSTM-based stacked autoencoders for early anomaly detection in induction heating systems. *Mathematics*, 2023, vol. 11, no. 15, p. 3319, DOI:10.3390/math11153319.
12. Lee Y., Park C., Kim N. et al. LSTM-autoencoder based anomaly detection using vibration data of wind turbines. *Sensors*, 2024, vol. 24, no. 9, p. 2833, DOI:10.3390/s24092833.
13. Sharma J., Mittal M.L., Soni G. Explainable artificial intelligence (XAI) enabled anomaly detection and fault classification of an industrial asset. *Research Square*, 2023, DOI:10.21203/rs.3.rs-2780708/v1.

14. Vasman S., Sukhanov I., Thalfeldt M. et al. Fault detection and diagnostics for HVAC systems using heat meter data, statistical features, and data mining. *Energy and Buildings*, 2026, art. no. 117343, DOI: 10.1016/j.enbuild.2026.117343.
15. Kurniawan H.M., Maulidan M., Zulmaulidin M.F. et al. Leveraging MongoDB in real-time emotion recognition from video for scalable and efficient data handling. *Engineering Proceedings*, 2025, vol. 107, no. 1, p. 84, DOI:10.3390/engproc2025107084.
16. Шкодырев В.П. Обзор методов обнаружения аномалий в потоках данных / В.П. Шкодырев, К.И. Ягафаров, В.А. Баштовенко // Proc. of the Second Conference on Software Engineering and Information Management. – Санкт-Петербург, 2017. – Т. 1864. – С. 7.
17. Исаева О.С. Инфраструктура сбора данных и имитации угроз безопасности сети интернета вещей / О.С. Исаева, Н.В. Кулясов, С.В. Исаев // Сибирский аэрокосмический журнал, 2025. – Т. 26. – № 1. – С. 8-20. – DOI: 10.31772/2712-8970-2025-26-1-8-20.

**Камышев Никита Львович.** Инженер отдела Красноярского математического центра Института вычислительного моделирования СО РАН. Область научных интересов: автоматизация процессов мониторинга, структуры систем передачи данных, аппаратура передачи данных, Cloud-Native и микросервисы, разработка десктопных приложений. ORCID: 0009-0008-4608-156X. [nik.novov@gmail.com](mailto:nik.novov@gmail.com).

**Исаева Ольга Сергеевна.** Доктор технических наук, ведущий научный сотрудник отдела Красноярского математического центра Института вычислительного моделирования СО РАН. Область научных интересов: методы искусственного интеллекта, анализ данных, цифровые двойники, информационная безопасность, интернет вещей. AuthorID: 165828, SPIN: 8412-5807, ORCID: 0000-0002-5061-6765, Researcher ID: A-8905-2018. [isaeva@icm.krasn.ru](mailto:isaeva@icm.krasn.ru). г. Красноярск, ул. Академгородок, д. 50, стр. 44, каб. 209.

UDC 004.822

DOI:10.25729/ESI.2026.42.2.016

## IoT device data monitoring tools

**Nikita L. Kamyshev, Olga S. Isaeva**

Institute of Computational Modelling SB RAS,

Russia, Krasnoyarsk, [nik.novov@gmail.com](mailto:nik.novov@gmail.com)

**Abstract.** This paper presents a solution for creating an autonomous microclimate monitoring system for technical facilities, capable of promptly detecting anomalies under conditions of non-stationary data and limited sensor infrastructure. The research aim is to develop monitoring tools that ensure continuous control, anomaly detection, and their interpretation. The core content of the work includes the development of a functional system model, the implementation of telemetry collection and heterogeneous data storage modules, and the deployment of an original hybrid algorithm for time series analysis. The key element is the proposed method, which combines spectral analysis to extract periodic signal components with adaptive statistical thresholds dynamically calculated based on sliding historical windows. Unlike existing counterparts relying on resource-intensive deep learning, the proposed approach utilizes physically grounded features to adapt to seasonal data variability without a preliminary training stage on labeled datasets. To unify the anomaly detection approach and alert routing, specific alert rules were configured, integration with a data visualization system was performed, and a chatbot was created to handle notifications and queries. To enhance fault tolerance, a component liveness control mechanism was implemented. The scientific novelty lies in proposing a hybrid adaptive anomaly detection method based on spectral-statistical time series analysis. The proposed approach ensures result interpretability by revealing the physical nature of failures through signal decomposition into harmonic components. Verification results on a real dataset of 5.3 million records confirmed the approach's effectiveness: detection recall reached 0.991 with a precision of 0.877. Load testing demonstrated the architecture's stability under low CPU utilization (<6%) and indicated reserves for scalability. The project successfully identified incidents related to air conditioning system malfunctions. The developed system provides a full cycle from data collection to preventive alerting, offering understandable diagnostic tools for preventing emergency situations while supporting two levels of interaction: a simplified interface for end-users and advanced analytical functions for specialists.

**Keywords:** Internet of Things (IoT), microclimate monitoring, anomaly detection, spectral analysis, adaptive thresholds, fault tolerance, Prometheus, AlertManager

**Acknowledgements:** This work is supported by the Krasnoyarsk Mathematical Center and financed by the Ministry of Science and Higher Education of the Russian Federation in the framework of the establishment and development of regional Centers for Mathematics Research and Education (Agreement No. 075-02-2026-735).

## References

1. Dovgal V.A., Dovgal D.V. Internet veshchey: kontseptsiya, prilozheniya i zadachi [Internet of Things: concept, applications and tasks]. Vestnik Adygeyskogo gosudarstvennogo universiteta. Ser. Estestvenno-matematicheskiye i tekhnicheskiye nauki [Bulletin of Adyghe state university. Series: Natural, Mathematical and technical sciences], 2017, no. 4(211), pp. 140–147.
2. Kumar S., Tiwari P., Zymbler M. Internet of Things is a revolutionary approach for future technology enhancement: a review. Journal of Big Data, 2019, no. 6, p. 111, DOI: 10.1186/s40537-019-0268-2.
3. Isaeva O.S., Kulyasov N.V., Isaev S.V. Formirovaniye adaptivnykh rassylok brokera dannykh interneta veshchey [Formation of adaptive mailings of the Internet of Things data broker]. Informatsionno-upravlyayushchiye sistemy [Information and control systems], 2022, no. 5 (120), pp. 23–31, DOI: 10.31799/1684-8853-2022-5-23-31.
4. Isaeva O.S., Kulyasov N.V., Isaev S.V. Sozdaniye instrumentov sbora dannykh dlya analiza aspektov bezopasnosti Interneta veshchey [Creation of data collection tools for analyzing Internet of Things security aspects]. Informatsionnyye i matematicheskiye tekhnologii v nauke i upravlenii [Information and mathematical technologies in science and management], 2022, no. 3(27), pp. 113–125, DOI:10.38028/ESI.2022.27.3.011.
5. Saputri F.R., Linelson R., Salehuddin M. et al. Design and development of an irrigation monitoring and control system based on blynk internet of things and thingspeak. PLoS ONE, 2025, vol. 20, no. 4, pp. 1–19, DOI:10.1371/journal.pone.0321250.
6. Spandonidis C., Tsantilas S., Sedikos E. et al. A compact, modular and low-cost Internet of Things (IoT) platform for air quality monitoring in urban areas. Journal of Physics: Conference Series, 2020, vol. 1710, no. 1, p. 012004, DOI:10.1088/1742-6596/1710/1/012004.
7. Yin hao L., Alqahtani A., Solaiman E. et al. IoT-CANE: A unified knowledge management system for data-centric Internet of Things application systems. Journal of Parallel and Distributed Computing, 2019, no. 131, pp. 161–172, DOI: 10.1016/j.jpdc.2019.04.016.
8. Tabiyev S., Orynbay A. IoT tekhnologii v sistemakh monitoringa mikroklimate pomeshcheniy [IoT technologies in indoor microclimate monitoring systems]. Vestnik KazATK [Bulletin of KazATC], 2024, no. 136(1), pp. 299–307, DOI: 10.52167/1609-1817-2025-136-1-299-307.
9. Kychkin A.V., Gorshkov O.V. Razrabotka programmnoy sistemy dlya upravleniya IoT-ustroystvami s ispol'zovaniyem strukturnykh i povedencheskikh patternov [Development of a software system for managing IoT devices using structural and behavioral patterns]. Prikladnaya informatika [Applied Informatics], 2020, vol. 15, no. 4, pp. 35–44, DOI: 10.37791/2687-0649-2020-15-4-35-44.
10. Gholamzadehmir M., Del Pero C., Buffa S. et al. Adaptive-predictive control strategy for HVAC systems in smart buildings – a review. Sustainable Cities and Society, 2020, vol. 63, p. 102480, DOI: 10.1016/j.scs.2020.102480.
11. Qais M.H., Kewat S., Loo K.H. et al. LSTM-based stacked autoencoders for early anomaly detection in induction heating systems. Mathematics, 2023, vol. 11, no. 15, p. 3319, DOI:10.3390/math11153319.
12. Lee Y., Park C., Kim N. et al. LSTM-autoencoder based anomaly detection using vibration data of wind turbines. Sensors, 2024, vol. 24, no. 9, p. 2833, DOI:10.3390/s24092833.
13. Sharma J., Mittal M.L., Soni G. Explainable artificial intelligence (XAI) enabled anomaly detection and fault classification of an industrial asset. Research Square, 2023, DOI:10.21203/rs.3.rs-2780708/v1.
14. Vasman S., Sukhanov I., Thalfeldt M. et al. Fault detection and diagnostics for HVAC systems using heat meter data, statistical features, and data mining. Energy and Buildings, 2026, art. no. 117343, DOI: 10.1016/j.enbuild.2026.117343.
15. Kurniawan H.M., Maulidan M., Zulmaulidin M.F. et al. Leveraging MongoDB in real-time emotion recognition from video for scalable and efficient data handling. Engineering Proceedings, 2025, vol. 107, no. 1, p. 84, DOI:10.3390/engproc2025107084.
16. Shkodiyev V.P., Yagafarov K.I., Bashtovenko V.A. Obzor metodov obnaruzheniya anomalii v potokakh dannykh [Review of anomaly detection methods in data streams]. Proceedings of the Second Conference on Software Engineering and Information Management, Saint Petersburg, 2017, vol. 1864, p. 7.
17. Isaeva O.S., Kulyasov N.V., Isaev S.V. Infrastruktura sbora dannykh i imitatsii ugroz bezopasnosti seti interneta veshchey [Data collection and threat simulation infrastructure for Internet of Things network security]. Sibirskiy aerokosmicheskii zhurnal [Siberian aerospace journal], 2025, vol. 26, no. 1, pp. 8–20, DOI: 10.31772/2712-8970-2025-26-1-8-20.

**Kamyshev Nikita Lvovich**, Engineer, Department of the Krasnoyarsk Mathematical Center, Institute of Computational Modelling SB RAS, Research interests: Automation of monitoring processes, data transmission system architectures, data transmission hardware, Cloud-Native and microservices, desktop application development. ORCID: 0009-0008-4608-156X. [nik.novov@gmail.com](mailto:nik.novov@gmail.com).

**Isaeva Olga Sergeevna**, Dr. Technical Sciences, Leading Researcher, Department of the Krasnoyarsk Mathematical Center, Institute of Computational Modelling SB RAS, Research interests: Artificial intelligence methods, data analysis, digital twins, information security, Internet of Things, AuthorID: 165828, SPIN: 8412-5807, ORCID: 0000-0002-5061-6765, Researcher ID: A-8905-2018. [isaeva@icm.krasn.ru](mailto:isaeva@icm.krasn.ru). Russia, Krasnoyarsk, Akademgorodok St., 50/44. Статья поступила в редакцию 15.10.2025; одобрена после рецензирования 24.03.2026; принята к публикации 25.05.2026.

*The article was submitted 10/15/2025; approved after reviewing 03/24/2026; accepted for publication 05/25/2026.*

