

Сетевой научно-практический журнал
**ИНТЕЛЛЕКТУАЛЬНЫЙ
ТРАНСПОРТ**

№4 (36)
ДЕКАБРЬ 2025



ИСКУССТВЕННЫЙ
ИНТЕЛЛЕКТ
И МАШИННОЕ
ОБУЧЕНИЕ

ИНТЕЛЛЕКТУАЛЬНЫЕ
ТРАНСПОРТНЫЕ
СИСТЕМЫ

ОБЗОРНЫЕ РАБОТЫ
ПО СОВРЕМЕННЫМ
НАУЧНЫМ ДОСТИЖЕНИЯМ
В ОБЛАСТИ ТРАНСПОРТА

ИНТЕЛЛЕКТУАЛЬНЫЙ ТРАНСПОРТ

Издается с 2017 года

Издатель:



АО «НИИАС»

Адрес редакции:

Россия, г. Москва, Орликов переулок,
д.5, стр.1 ком. 824 1

Email: journal@vniias.ru

Телефон: +7 (495) 967-77-01

Сайт: <http://www.intelligent-transport.ru/>

Сетевой научно-практический журнал «Интеллектуальный транспорт» публикует основные научные результаты соискателей учёной степени кандидата и доктора наук по следующим специальностям и соответствующим им отраслям науки:

Журнал включен в базу данных Российского индекса научного цитирования (РИНЦ)

Сетевой научно-практический журнал «Интеллектуальный транспорт» публикует основные научные результаты соискателей учёной степени кандидата и доктора наук по следующим специальностям и соответствующим им отраслям науки:

- 1.2.1. Искусственный интеллект и машинное обучение (технические науки)
- 2.9.1. Транспортные и транспортно-технологические системы страны, ее регионов и городов, организация производства на транспорте (технические науки)
- 2.9.4. Управление процессами перевозок (технические науки)
- 2.9.8. Интеллектуальные транспортные системы (технические науки)

Полная или частичная перепечатка, сканирование любого материала текущего номера возможны только с письменного разрешения редакции.

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

ГЛАВНЫЙ РЕДАКТОР

Суханов Андрей Валерьевич

к.т.н., доцент, заместитель начальника Отделения инновационных и интеллектуальных технологий цифровой станции Ростовского филиала АО «НИИАС»

Выпускающий редактор

Левшина Анна Андреевна

Инженер-программист 1 категории Технологического сектора Ростовского филиала АО «НИИАС»

Алиев Вугар Амирович

д.ф.-м.н., профессор, главный научный сотрудник Института физики Республики Азербайджан (Республика Азербайджан)

Бородин Андрей Федорович

д.т.н., профессор, начальник отдела АО «ИЭРТ»

Бочков Константин Афанасьевич

д.т.н., профессор «БелГУТ» (Республика Беларусь)

Броневич Андрей Георгиевич

д.ф.-м.н., главный научный сотрудник АО «НИИАС»

Бутакова Мария Александровна

д.т.н., профессор, главный научный сотрудник Ростовского филиала АО «НИИАС»

Грибова Валерия Викторовна

чл.-корр. РАН, д.т.н., профессор, заместитель директора по научной работе ДВО РАН

Гришаев Сергей Юрьевич

к.т.н., заместитель Генерального директора – директор Ростовского филиала АО «НИИАС»

Гуров Юрий Владимирович

к.т.н., начальник Центра разработки программного обеспечения Ростовского филиала АО «НИИАС»

Долгий Игорь Давидович

д.т.н., профессор, Научный руководитель лаборатории РГУПС

Ковалев Сергей Михайлович

д.т.н., профессор, научный руководитель Ростовского филиала АО «НИИАС»

Коваленко Николай Иванович

д.т.н., профессор РУТ (МИИТ)

Котенко Алексей Геннадьевич

д.т.н., профессор, главный научный сотрудник АО «ВНИИЖТ»

Ли Инь

к.ф.-м.н., доцент Харбинского технологического института (КНР)

Матюхин Владимир Георгиевич

д.т.н., председатель Экспертного совета АО «НИИАС»

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА

Розенберг Ефим Наумович

д.т.н., профессор, первый заместитель Генерального директора АО «НИИАС»

Ответственный секретарь

Соловьева Юлия Геннадьевна

Главный специалист Департамента корпоративных коммуникаций АО «НИИАС»

Ольгейзер Иван Александрович

к.т.н., доцент, первый заместитель директора Ростовского филиала АО «НИИАС»

Папич Любиша

д.т.н., профессор, директор Исследовательского центра DQM (Республика Сербия)

Попов Павел Александрович

к.т.н., заместитель генерального директора – директор Санкт-Петербургского филиала АО «НИИАС»

Сабанов Алексей Геннадьевич

д.т.н., главный эксперт Научно-технического комплекса технологий информационного общества АО «НИИАС»

Соколов Сергей Викторович

д.т.н., профессор РГУПС, главный научный сотрудник АО «НИИАС»

Хабаров Валерий Иванович

д.т.н., профессор, заведующий кафедрой СГУПС

Хатламаджиян Агоп Ервандович

к.т.н., доцент, заместитель генерального директора АО «НИИАС»

Чжан Дачжи

Профессор Харбинского технологического института (КНР)

Шабалин Николай Григорьевич

д.т.н., профессор, руководитель Департамента научных исследований, аналитики и совершенствования научно-технической деятельности АО «НИИАС»

Шубинский Игорь Борисович

д.т.н., профессор, главный эксперт Департамента научных исследований, аналитики и совершенствования научно-технической деятельности АО «НИИАС»

Юдин Дмитрий Александрович

к.т.н., старший научный сотрудник, заведующий лабораторией МФТИ

Яковлев Константин Сергеевич

к.ф.-м.н., ведущий научный сотрудник ФИЦ ИУ РАН

ОГЛАВЛЕНИЕ

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МАШИННОЕ ОБУЧЕНИЕ

Пазойский Ю.О., Вакуленко С.П., Калинин К. А., Сидоренко Н.А., Уваров А.А. АЛГОРИТМИЗАЦИЯ ПОРЯДКА НАЗНАЧЕНИЯ ЛОКОМОТИВНЫХ БРИГАД В ГРАФИКЕ ОБОРОТА ПРИГОРОДНЫХ ЭЛЕКТРОПОЕЗДОВ	5
Комисарчук А.В., Елисеев И.А., Сидоров А.В. ПРИМЕНЕНИЕ ГЛУБИННОГО ОБУЧЕНИЯ ДЛЯ ПРЕДСКАЗАНИЯ ОТКАЗОВ ПОДВИЖНОГО СОСТАВА	14
Борисов В.В., Булыгина О.В., Зубарева В.Н. СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ УПРАВЛЕНИЯ ВОЗВРАТАМИ В ЭЛЕКТРОННОЙ КОММЕРЦИИ НА ОСНОВЕ АЛГОРИТМА ДОЖДЕВЫХ ЧЕРВЕЙ И НЕЧЕТКОГО СЛУЧАЙНОГО ЛЕСА	25
Беляков С.Л. Израилев Л.А. ПОСТРОЕНИЕ КАРТЫ РАСПРЕДЕЛЕНИЯ АНОМАЛИЙ ИСПОЛНЕНИЯ ЛОГИСТИЧЕСКИХ ПРОЕКТОВ В УСЛОВИЯХ НЕОПРЕДЕЛЁННОСТИ	42

ИНТЕЛЛЕКТУАЛЬНЫЕ ТРАНСПОРТНЫЕ СИСТЕМЫ

Котенко А.Г., Котенко О.В. ПРОИЗВОДИТЕЛЬНОСТЬ ТРУДА ЛОКОМОТИВНЫХ БРИГАД КАК КРИТЕРИЙ КАЧЕСТВА УПРАВЛЕНИЯ ПОЕЗДНОЙ РАБОТОЙ	56
Свистельников А.А., Малыхина П.В., Григорьева А.М., Кумалов Т.З. МЕТОДЫ ИСПЫТАНИЙ ДЛЯ ОЦЕНКИ СООТВЕТСТВИЯ ПОДСИСТЕМЫ ДОРОЖНОГО ВИДЕОНАБЛЮДЕНИЯ В СОСТАВЕ ИНТЕЛЛЕКТУАЛЬНЫХ ТРАНСПОРТНЫХ СИСТЕМ	65

ОБЗОРНЫЕ РАБОТЫ ПО СОВРЕМЕННЫМ НАУЧНЫМ ДОСТИЖЕНИЯМ В ОБЛАСТИ ТРАНСПОРТА

Долгий А.И., Кудюкин В.В., Хатламаджиян А.Е., Шаповалов В.В. КОНТРОЛЬ И ДИАГНОСТИКА ПОДВИЖНОГО СОСТАВА – ОТ ОДИНОЧНЫХ УСТРОЙСТВ ДО РОБОТИЗИРОВАННЫХ ДИАГНОСТИЧЕСКИХ КОМПЛЕКСОВ	76
Куверин И.Ю., Гусев С.А., Блинов Д.Г. БЕЗОПАСНОСТЬ АВТОНОМНЫХ ТРАНСПОРТНЫХ СРЕДСТВ: КОМПЛЕКСНЫЙ АНАЛИЗ И СТРАТЕГИЧЕСКИЕ ПЕРСПЕКТИВЫ	102



НИИАС — лауреат Премии Правительства РФ в области науки и техники



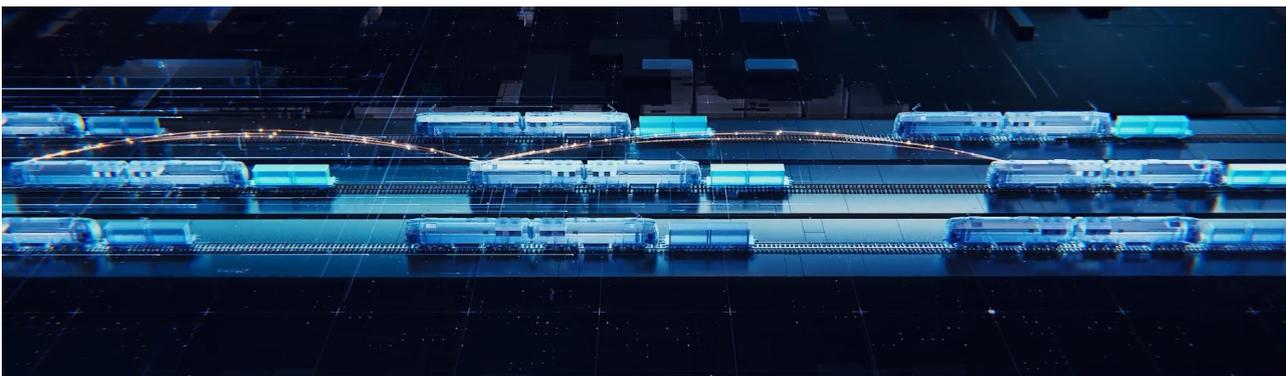
АО «НИИАС» — лауреат Премии Правительства Российской Федерации в области науки и техники.

2 декабря коллектив разработчиков АО «НИИАС», ОАО «РЖД» и ООО «ТМХ Интеллектуальные системы» стал лауреатом Премии Правительства Российской Федерации в области науки и техники за разработку и внедрение комплекса интеллектуальных технологий управления перевозочным процессом в условиях реконструкции Восточного полигона.

Награда присуждена за создание и практическое внедрение решений, направленных на повышение пропускной способности железнодорожной инфраструктуры, эффективности организации перевозочного процесса и устойчивости работы сети в условиях масштабных инфраструктурных ограничений. Разработанные технологии уже применяются на объектах Восточного полигона и обеспечивают значимый производственный и экономический эффект.

Особое место в комплексе разработок занимает технология виртуальной сцепки, которая рассматривается как один из ключевых инструментов цифрового развития железнодорожного транспорта. Применение данной технологии позволяет увеличивать объёмы перевозок без строительства дополнительной инфраструктуры и формирует основу для дальнейшего развития интеллектуальных и автоматизированных систем управления движением поездов.

Получение Премии Правительства Российской Федерации подтверждает высокий научно-технический уровень разработок и вклад специалистов НИИАС и организаций-партнёров в развитие отечественных технологий управления перевозочным процессом и цифровую трансформацию железнодорожного транспорта.



УДК 656.222.3

АЛГОРИТМИЗАЦИЯ ПОРЯДКА НАЗНАЧЕНИЯ ЛОКОМОТИВНЫХ БРИГАД В ГРАФИКЕ ОБОРОТА ПРИГОРОДНЫХ ЭЛЕКТРОПОЕЗДОВ

Пазойский Юрий Ошарович, д.т.н., профессор, заведующий кафедрой «Железнодорожные станции и транспортные узлы», Российский университет транспорта, Москва, Россия, E-mail: pazoyskiy@mail.ru
Вакуленко Сергей Петрович, к.т.н., профессор, заместитель директора Научно-исследовательского института транспорта, заведующий кафедрой «Управление транспортным бизнесом и интеллектуальные системы», Российский университет транспорта, Москва, Россия, Email: post-iuit@bk.ru
Калинин Кирилл Антонович, к.т.н., доцент кафедры «Управление транспортным бизнесом и интеллектуальные системы», Российский университет транспорта, Москва, Россия, Email: kalinin.k.a@mail.ru
Сидоренко Никита Александрович, ведущий инженер НТК ЦМ В.И Уманского АО НИИАС, Москва, Россия, Email: sidorenko345@mail.ru
Уваров Алексей Антонович, ведущий инженер НТК ЦМ В.И Уманского АО НИИАС, Москва, Россия, Email: alex.dom.info@gmail.com

АННОТАЦИЯ

В представленной статье описывается алгоритм, разработанный авторами для построения графика оборота пригородных поездов. Целью разработки является минимизация совокупного времени простоя локомотивных бригад в периоды ожидания движения поездов. Следствием данной оптимизации выступает сокращение потребности штатной численности бригад и операционных затрат на организацию перевозок на участках с высокой интенсивностью движения электропоездов. Описание предложенного алгоритма формализовано в виде блок-схемы, которая определяет логику назначения локомотивных бригад. В модель заложены следующие ограничения: минимально допустимое время оборота, а также установленные нормы труда и отдыха для персонала.

Ключевые слова: График оборота поездов, локомотивная бригада, оборотный тупик, путь оборота, график движения, блок-схема

ALGORITHMIZATION OF THE ORDER OF APPOINTMENT OF LOCOMOTIVE CREWS IN THE SCHEDULE OF TURNOVER OF SUBURBAN ELECTRIC TRAINS

Yuri O. Pazoyskiy, Doctor of Technical Sciences, Professor, Head of the Department of Railway Stations and Transport Hubs, Russian University of Transport, Moscow, Russia, Email: pazoyskiy@mail.ru
Sergey P. Vakulenko, Ph.D., Professor, Deputy Director of the Transport Research Institute, Head of the Department of Transport Business Management and Intelligent Systems, Russian University of Transport, Moscow, Russia, E-mail: post-iuit@bk.ru
Kirill A. Kalinin, PhD, Associate Professor of the Department of Transport Business Management and Intelligent Systems, Russian University of Transport, Moscow, Russia, E-mail: kalinin.k.a@mail.ru
Nikita A. Sidorenko, Leading Engineer of the Scientific and Technical Committee of the Central Research Institute of Economics and Umansky JSC NIIAS, Moscow, Russia, E-mail: sidorenko345@mail.ru
Alexey A. Uvarov, Leading Engineer of the Scientific and Technical Committee of the Central Research Institute of Economics and Umansky JSC NIIAS, Moscow, Russia, E-mail: alex.dom.info@gmail.com

ABSTRACT

This article describes an algorithm developed by the authors for constructing a commuter train turnaround schedule. The goal is to minimize the total downtime of locomotive crews while waiting for trains to depart. This optimization results in a reduction in the required crew complement and operating costs for organizing service on sections with high commuter train traffic. The description of the proposed algorithm is formalized in the form of a flowchart that defines the logic for assigning locomotive crews. The model incorporates the following constraints: minimum allowable turnaround time, as well as established work and rest standards for personnel.

Keywords: Train turnaround schedule, locomotive crew, turnaround dead end, turnaround route, traffic schedule, block diagram.

Введение

Организация движения пригородных электропоездов в крупных агломерациях является сложным и комплексным процессом, для реализации которого необходимо разработать, согласовать и апробировать ряд технологических документов, которые регулируют работу всех элементов транспортной инфраструктуры, участвующих в перевозочном процессе.

Разработка графика оборота пригородных электропоездов и графика работы локомотивных бригад для пригородных электропоездов в Московском узле требует детальной проработки и оптимизации графика движения поездов. Принятие иррациональных решений при разработке данных технологических документов могут привести к эксплуатационным потерям, завышенному простоя локомотивных бригад в ожидании отправления и неравномерному размещению ниток пригородных электропоездов в графике движения и графике оборота.

Рассмотрим типовой процесс оборота пригородного электропоезда на примере эксплуатации участка, где движения поездов организовано по принципу транзитного проследования городской части маршрута с остановками, и поезда проследуют из области в область. Фрагмент операций по смене головной кабины управления представлен на рисунке 1 (фрагмент а - прибытие и фрагмент б - отправление).

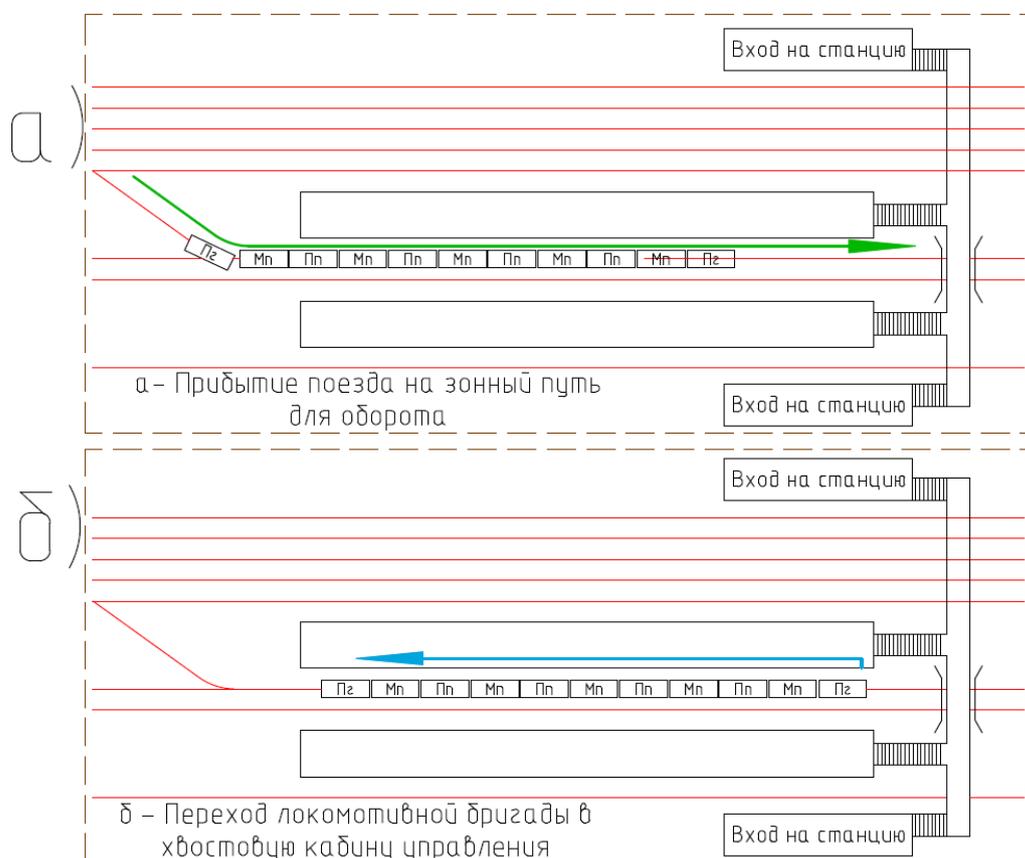


Рис. 1 – Фрагмент оборота пригородного электропоезда на зонном пути станции Л

На фрагменте (а) изображен процесс прибытия пригородного поезда на зонный путь рассматриваемой станции. После остановки поезда пассажиры покидают вагоны электропоезда, а локомотивная бригада приступает к выполнению технологического алгоритма по смене кабины управления. На рисунке 1(б) представлен маршрут перехода помощника машиниста из головной кабины в хвостовую. В это время машинист локомотивной бригады выполняет операции по отключению головной кабины управления, а затем также переходит в хвостовую кабину. После приведения кабины в рабочее состояние, члены бригады осуществляют сокращённую проверку тормозов, и после регламента «минутной готовности» отправляются со станции, рисунок 2 (в).

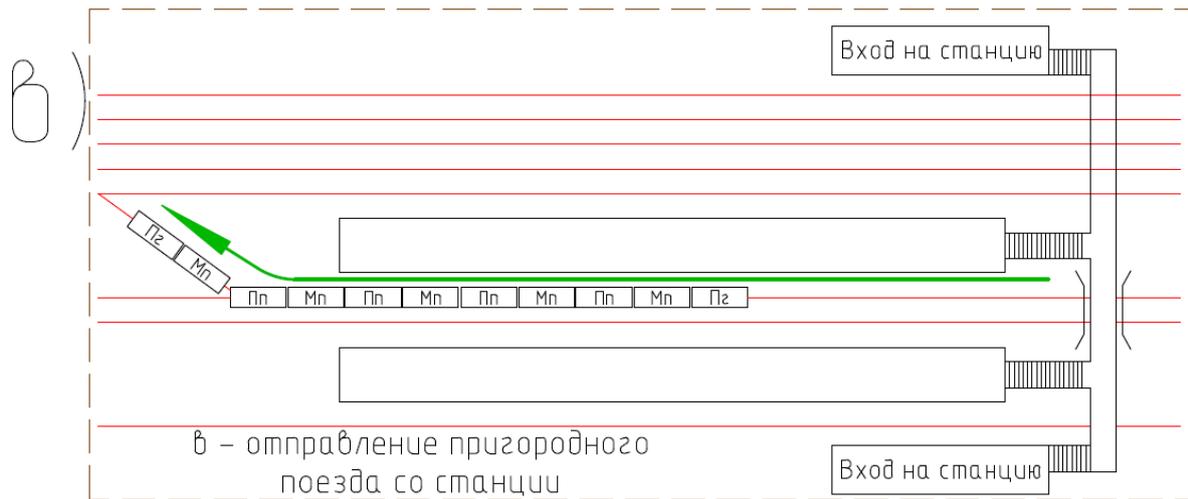


Рис. 2 – Отправление поезда со станции

Преимущество технологии оборота состава на зонном пути заключается в проведении операций по смене кабины управления непосредственно у платформы. Это обеспечивает возможность параллельного выполнения операций по смене кабины управления и проведении посадки/высадки пассажиров [1].

1. Формализация алгоритма назначения локомотивных бригад

При разработке метода автоматизированного назначения локомотивных бригад в графике оборота подвижного состава и локомотивных бригад, требуется определить систему выбора нитки графика движения поездов с учётом всех имеющихся входных параметров. Для Московского железнодорожного узла действует норматив времени на оборот пригородного электропоезда от 12 до 15 минут, точное время зависит от количества вагонов в составе поезда [2-5]. Фрагмент назначения оборота пригородного электропоезда приведен на рисунке 3.

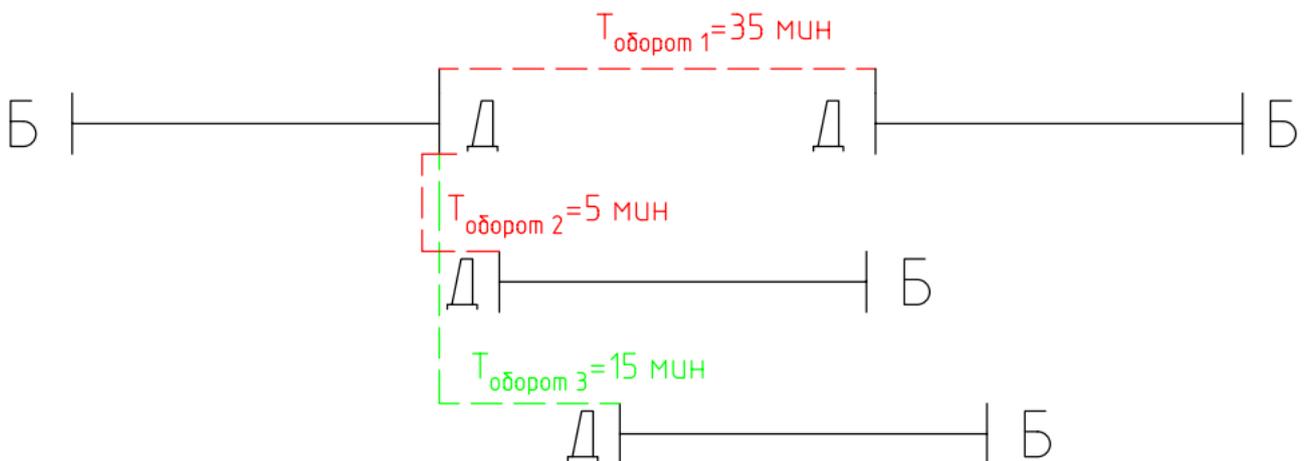


Рис. 3 – Схема выбора оптимального маршрута для размещения локомотивной бригады

На разработанной схеме приведен пример выбора оптимального нитки следования для локомотивной бригады, с учетом ограничений по времени на смену кабины управления. При минимизации времени простоев, локомотивная бригада способна совершить большее число рейсов, за общее время рабочей смены, однако необходимо учитывать ограничение на

установленный режим работы и отдыха локомотивной бригады. Применение описываемого алгоритма позволит минимизировать нерациональные простои локомотивных бригад без нарушения медицинских, эргономических и физиологических ограничений их работы:

$$T_{\text{раб}}^i \rightarrow T_{\text{Общ}} - T_{\text{Отд}} \quad (1),$$

где: $T_{\text{Общ}}$ – продолжительность смены локомотивной бригады, часов; $T_{\text{раб}}^i$ – суммарное время, которое проводит i локомотивная бригада в кабине управления, часов; $T_{\text{Отд}}$ – гарантируемое работодателем время нахождения в доме отдыха локомотивных бригад, часов.

Рабочим временем локомотивной бригады считается то время, когда локомотивная бригада находится в пути, стремящееся к $T_{\text{Общ}}$.

Оптимизация работы одной конкретной локомотивной бригады создаёт перед графистами участка другую технологическую задачу, а именно необходимость увязки графика оборота на зонных станциях [6-8]. При условии выбора из нескольких вариантов следует осуществлять назначение бригады по принципу максимизации полезного времени работы бригады, а также увеличению её суточного пробега. На рисунке 4 представлена схема выбора постановки при назначении локомотивной бригады на маршрут.

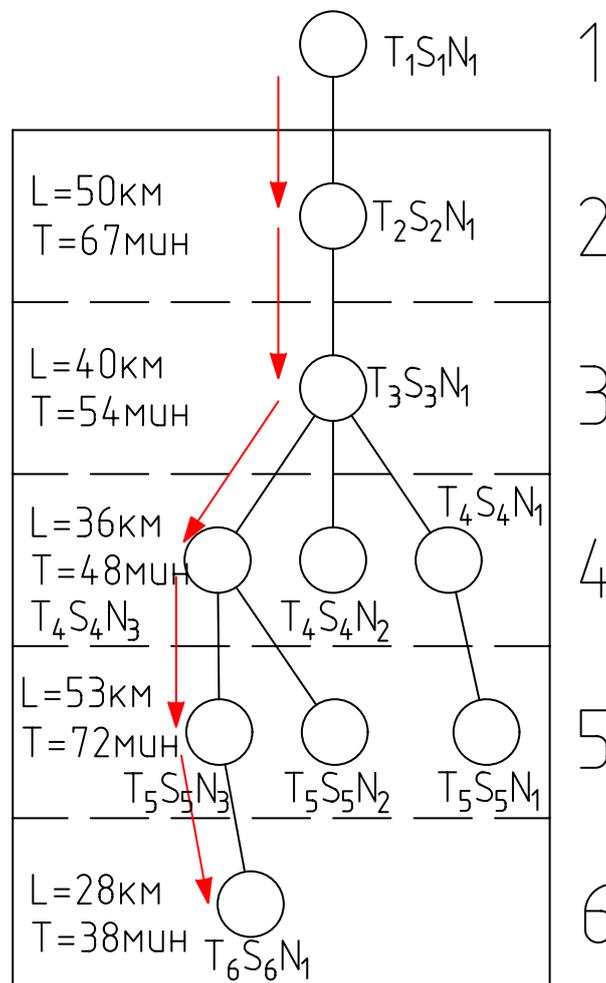


Рис. 4 – Схема постановки локомотивной бригады на маршрут

На рисунке 4 отображены все варианты назначения локомотивной бригады на рейс в течение суток. При использовании описанной технологии принятия решения об оптимальном размещении бригады на поезд, то есть выборе последующей ветви, обусловлен временем $T_{\text{раб}}^i$, стремящимся к нормативному времени работы локомотивной бригады, а также показателем пройденного расстояния S , значение которого, целесообразно выбирать наибольшим. Исходя из рисунка 4 маршрут бригады на рассматриваемые сутки принимает следующий вид:

$$T_1 S_1 N_1 \rightarrow T_2 S_2 N_1 \rightarrow T_3 S_3 N_1 \rightarrow T_4 S_4 N_3 \rightarrow T_5 S_5 N_3 \rightarrow T_6 S_6 N_1$$

В приведенном примере по заданному маршруту суммарное расстояние, преодолеваемое локомотивной бригадой, составляет 207 км. Общее время хода по перегонам составляет 4 часа 39 минут.

При разработке графика оборота поездов и назначении локомотивных бригад на рейсы предлагается использовать алгоритм, представленный на рисунке 5.

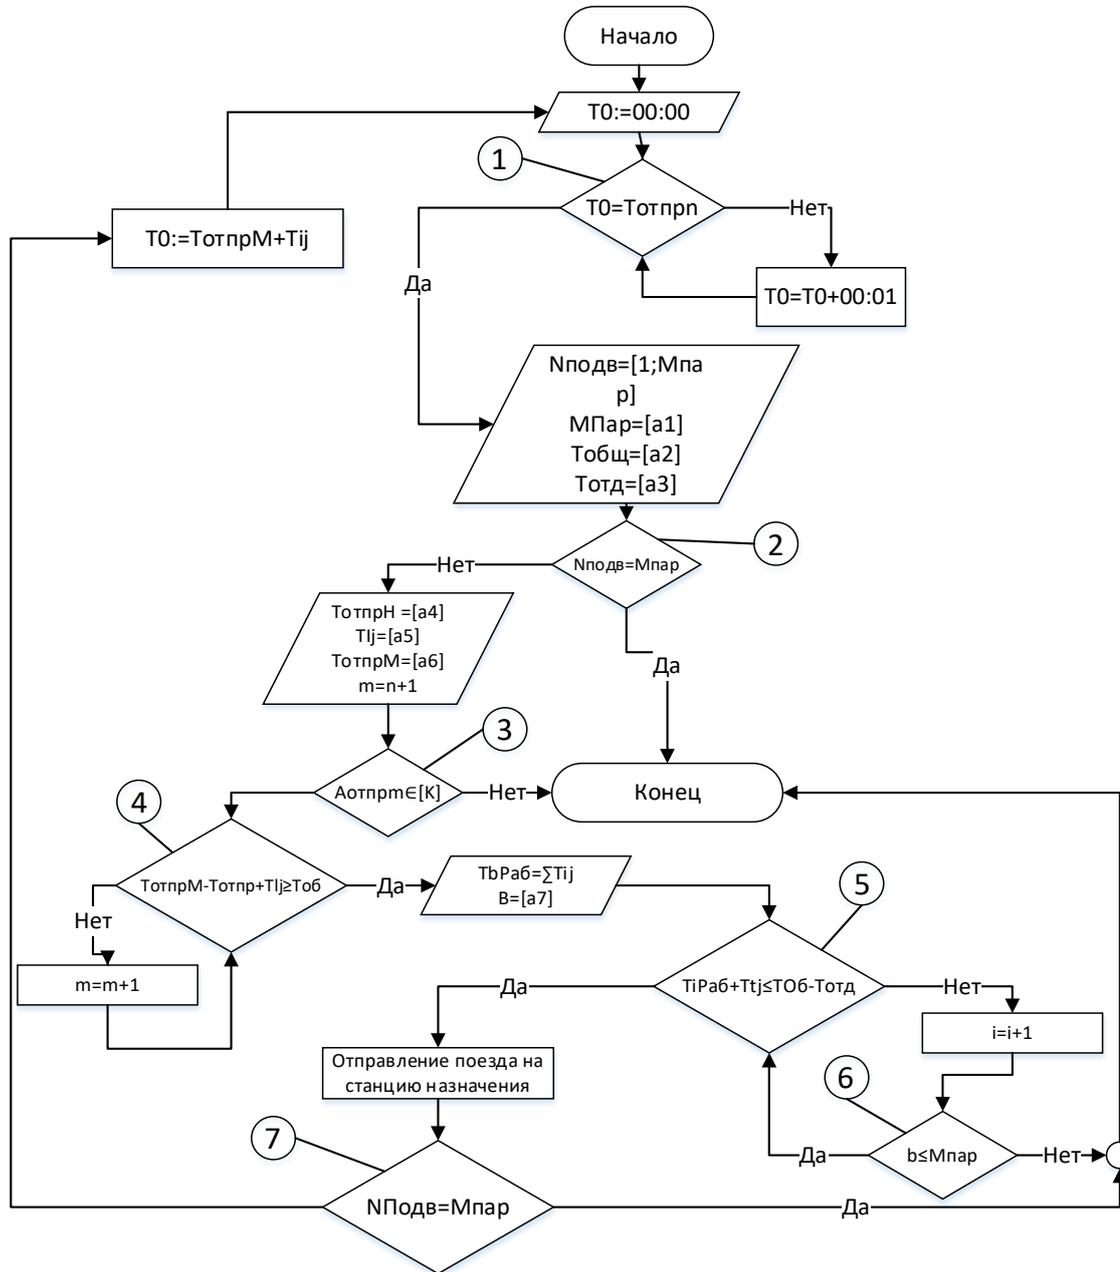


Рис. 5 – Блок-схема процесса назначения

Используемые обозначения:

T_0 – задаваемый временной параметр, указывающий начало работы алгоритма; $N_{\text{подв}}$ – количество пар ниток графика движения занесённых в график оборота; $M_{\text{пар}}$ – количество пар поездов в графике движения; A – массив данных о графике движения; n – номер нитки; m – номер следующей выбранной нитки; b – номер локомотивной бригады; $A_{\text{отпр}}^m$ – станция отправления нитки m ; $T_{\text{отпр}}^n$ – время отправления рассматриваемой нитки; T_i^j – время

проследования i нитки по j маршруту; $T_{отпр}^m$ – время отправления второй нитки в подвязываемой паре; K – массив данных о станциях, остановочных и отдельных пунктах на рассматриваемом перегоне; $T_{об}$ – нормативное время продолжительности оборота пригородного состава на станции, где осуществляется оборот.

Алгоритм на рисунке 5 разработан для внедрения в процесс составления графика оборота пригородных поездов упорядоченного порядка действий. В условиях, когда за счёт средств автоматизации (АРМ-графиста или Эльбрус) [9,10] нормативный график движения поездов создаётся сотрудниками вручную, на этапе разработки могут возникать ошибки по причине человеческого фактора, так как технологу-графисту необходимо учитывать сведения, предоставляемые дирекцией тяги, вагонниками, планы по техническому обслуживанию и капитальному ремонту.

В настоящий момент в отечественной практике эксплуатации пассажирского железнодорожного транспорта отсутствуют какие-либо внутренние нормативные документы или должностные инструкции, регулирующие процесс назначения локомотивных бригад при составлении графика оборота. Разработанный авторами алгоритм направлен на уменьшение вероятности принятия не рационального решения при выборе локомотивной бригады с целью её назначения на рассматриваемую нитку поезда [11]. В условиях отсутствия централизованного подхода, формализованного алгоритма, и внедрение ПО, обеспечивающего воспроизводимость результатов процесса назначения локомотивных бригад процесс их назначения в значительной степени подвержен человеческому фактору и субъективизму.

Блок-схема осуществляет выбор подходящей бригады в результате проверки 7 условий. В случае, если все условия удовлетворяют заданным требованиям эксплуатации участка, то бригада считается назначенной на конкретный рейс.

Условие №1 в представленной блок-схеме отвечает за поиск ближайшей свободной нитки. Поиск осуществляется посредством итерационного продвижения времени начала цикла на 1 минуту. В случае, если время начала цикла соответствует времени отправления нитки, алгоритм продолжает проверку последующих условий для поезда под соответствующим номером.

Проверка условия №2 заключается в определении количества ниток графика, уже указанных в графике оборота. Алгоритм продолжает работу в случае, если количество пар ниток не соответствует заданным размерам движения на участке. В случае, если значение $N_{подв}$ равняется $M_{пар}$ цикл завершается, поскольку в график оборота занесены все существующие нитки.

На третьем этапе проверяется возможность организации операции по обороту на станции отправления подвязываемой нитки $A_{отпр}^m$. Определение возможности осуществляется за счёт анализа массива данных K , который содержит информацию о техническом оснащении станций на моделируемом участке.

Затем алгоритм проверяет разницу между временем отправления нитки m и временем прибытия выбранного поезда n . Если полученное значение больше или равно нормативной продолжительности оборота пригородного электропоезда, установленного на рассматриваемом участке, скрипт переходит к проверке соблюдения условий труда локомотивной бригады.

В условии №5 осуществляется проверка выполнения обязательных норм по длительности смены и отдыху локомотивной бригады. В случае если сумма показателя накопленной полезной работы и продолжительности предстоящего рейса меньше, чем разница общей продолжительности смены и времени, выделяемого на отдых, то локомотивная бригада назначается на рассматриваемую поездку. Затем алгоритм повторно проверит количество ниток в графике оборота относительно показателя парности нормативного графика движения поездов. В случае, если условие $N_{подв} = M_{пар}$ выполняется алгоритм завершает работу. В противном случае алгоритм начнёт поиск последующих ниток, то есть начнёт цикл с начала. Таким образом время T_0 принимает следующий вид:

$$T_0 = T_{отпр}^m + T_t^j \quad (2)$$

С целью апробации алгоритма был разработан фрагмент графика движения поездов. На рисунке 6 приведен фрагмент графика движения поездов с учётом пикового и непикового периода.

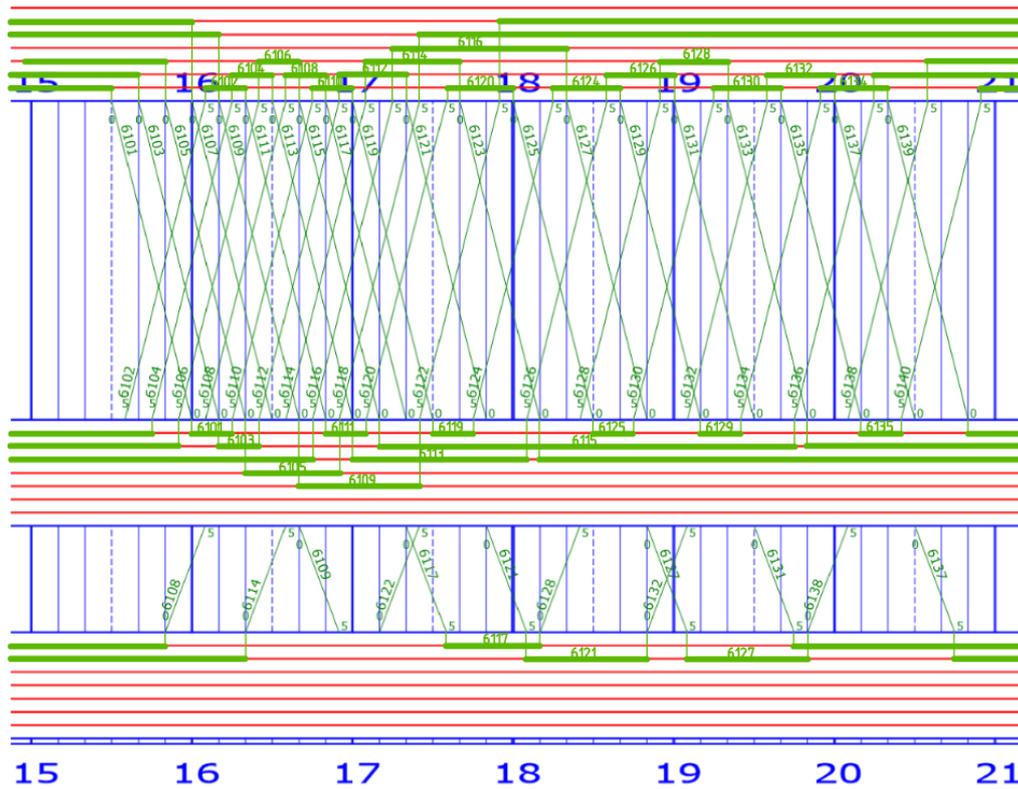


Рис. 6 – Фрагмент графика движения поездов

Стоит отметить, что алгоритм на рисунке 5 предназначен для железнодорожных участков, оборот на которых осуществляется на конечных станциях участка. Соответственно, алгоритм не учитывает возможность смены локомотивной бригады в пути следования на промежуточных станциях или остановочных пунктах.

На основе фрагмента графика движения поездов и предлагаемого алгоритма был разработан график оборота локомотивных бригад рассматриваемого участка. График оборота представлен на рисунке 7.

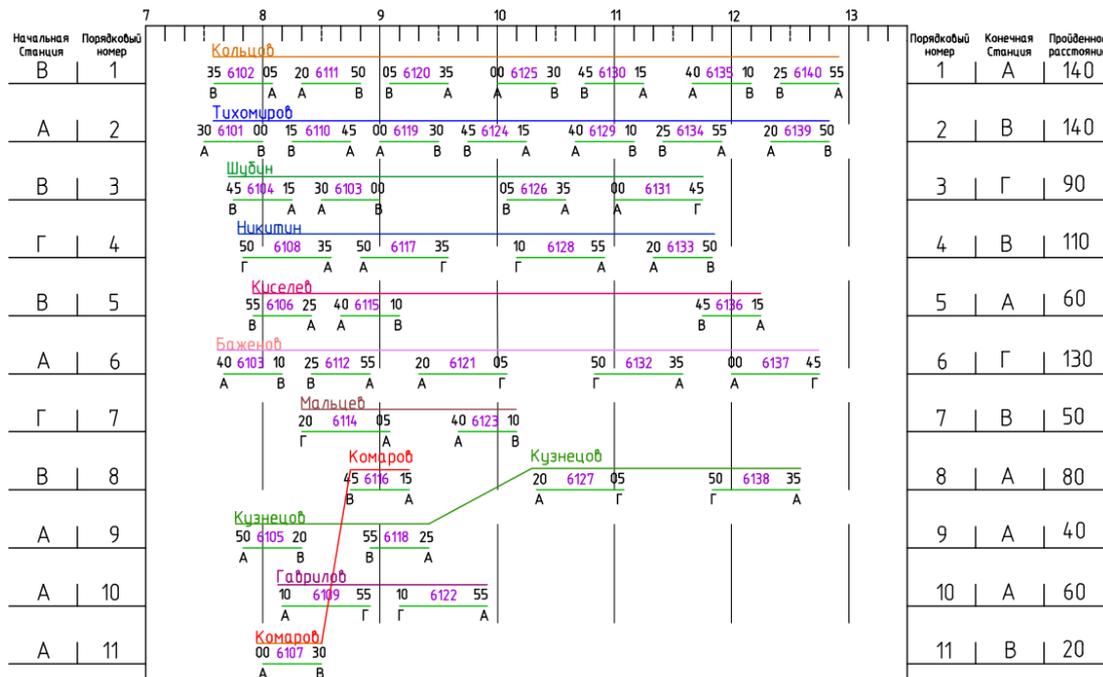


Рис. 7 – Фрагмент графика оборота локомотивных бригад

Исходя из данных, полученных при разработке графика оборота, определяется продолжительность работы локомотивных бригад, назначенных на рассматриваемые нитки. Накопленное время работы локомотивных бригад представлено в таблице 1.

Таблица 1

Показатели работы локомотивных бригад

№	Локомотивная бригада	Время работы, мин
1	Кольцов	210
2	Тихомиров	210
3	Шубин	135
4	Никитин	180
5	Киселев	90
6	Баженов	150
7	Мальцев	75
8	Кузнецов	90
9	Гаврилов	180
10	Комаров	60

Заключение

Применение разработанного алгоритма позволяет отслеживать динамику показателей работы участка и локомотивных бригад при изменении характеристик пассажира. Так для обеспечения качественного перевозочного процесса и необходимой провозной ёмкости пассажирского сообщения в пиковые часы интенсивность движения пригородных поездов увеличивается, что в обозначенном примере эквивалентно добавлению трёх дополнительных ниток в графике движения поездов. В часы пик, при интенсификации движения по участку для обеспечения смены головы пригородного электропоезда требуется оборудовать третий дополнительный путь для совершения оборота пригородных поездов, по причине нехватки свободных станционных путей, в связи с 15 минутным нормативом на оборот поездов.

Согласно принципам минимизации времени простоя локомотивных бригад, в ожидании нитки графика был описан разработанный алгоритм формирования рационального графика оборота локомотивных бригад. Также фактором, влияющим на работу разработанного метода, являлась продолжительность смены заданной локомотивной бригады.

В ходе выполнения работы были также разработаны фрагменты графика движения поездов в пиковый и непиковый период с применением разработанной методики размещения локомотивных бригад в графике оборота. Предложенная методика позволяет минимизировать время простоя локомотивных бригад, тем самым повышая суммарное время нахождения в кабине управления и эффективность её работы.

Список использованной литературы

1. Разработка единой технологии работы пригородных участков с различными межпоездными интервалами / С. П. Вакуленко, Д. Ю. Роменский, К. А. Калинин, А. Д. Ершов // *Интеллектуальные транспортные системы: материалы III Междунар. науч.-практ. конф.*, Москва, 30 мая 2024 г. – М.: Рос. ун-т транспорта (МИИТ), 2024. – С. 63–70. – DOI 10.30932/9785002446094-2024-63-70.

2. Роменский Д. Ю. Пригородно-городские железнодорожные пассажирские перевозки на диаметральных маршрутах крупных транспортных узлов (на примере Московского транспортного узла): дис. ... канд. техн. наук: 05.22.08. – М., 2021. – 240 с.
3. Биленко Г. М., Волков В. С. График оборота локомотивов как основа графика движения грузовых поездов // *Наука и техника транспорта*. – 2016. – № 2. – С. 79–86;
4. Роменский Д. Ю., Калинин К. А., Кулалаева М. В. Разработка принципов формирования клиентоориентированного графика движения поездов в пригородно-городских пассажирских перевозках // *Интеллектуальные транспортные системы: материалы II Междунар. науч.-практ. конф.*, Москва, 25 мая 2023 г. – М.: Рос. ун-т транспорта, 2023. – С. 330–337. – DOI 10.30932/9785002182794-2023-330-337.
5. Бакин А. А. Алгоритм построения графика движения поездов с тактовым расписанием движения пригородных поездов // *Кочневские чтения – 2023: современная теория и практика эксплуатационной работы железных дорог: труды II Междунар. науч.-практ. конф.*, Москва, 19–20 апр. 2023 г. – М.: Рос. ун-т транспорта (МИИТ), 2023. – С. 316–321.
6. Козлов П. А., Копылова Е. В. Оптимизация оборота составов по обеспечению ниток графика пригородного движения // *Наука и техника транспорта*. – 2020. – № 2. – С. 68–73.
7. Бакин А. А. Метод разработки тактового графика движения пригородных поездов: автореф. дис. ... канд. техн. наук: 05.22.08. – М.: Рос. ун-т транспорта, 2024. – 24 с.
8. Организация пригородных железнодорожных перевозок: транспортные средства. Эксплуатация железных дорог: учеб. пособие / Ю. О. Пазойский, С. П. Вакуленко, А. В. Колин и др.; Учеб.-метод. центр по образованию на железнодорожном транспорте. – М.: ФГБУ ДПО «Учебно-методический центр по образованию на железнодорожном транспорте», 2015. – 270 с. – ISBN 978-5-89035-816-5.
9. Использование системы «ЭЛЬБРУС-Учебный» для подготовки студентов по специальности «Эксплуатация железных дорог» / С. П. Вакуленко, М. И. Мехедов, Д. Ю. Роменский и др. // *Железнодорожный транспорт*. – 2023. – № 4. – С. 50–54.
10. Цифровая прогнозная макромодель движения поездопотоков ЭЛЬБРУС-М / В. Ю. Кирякин, А. Г. Сахаров, С. А. Виноградов и др. // *Железнодорожный транспорт*. – 2024. – № 4. – С. 4–11.
11. Управление качеством графика движения поездов в железнодорожных узлах с интенсивным пригородным движением / С. П. Вакуленко, Д. Ю. Роменский, К. А. Калинин, М. В. Лукинская // *Транспорт: наука, техника, управление*. – 2024. – № 5. – С. 30–40. – DOI 10.36535/0236-1914-2024-05-5.

УДК 629.4.053.2

ПРИМЕНЕНИЕ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ПРЕДСКАЗАНИЯ ОТКАЗОВ ПОДВИЖНОГО СОСТАВА

Комисарчук Алексей Васильевич, главный системный аналитик, АО «ВНИИЖТ», Москва, Россия,

E-mail: komisarchuk.aleksei@vniizht.ru

Елисеев Игорь Александрович, начальник отдела, к.т.н., АО «ВНИИЖТ», Москва, Россия,

E-mail: eliseev.igor@vniizht.ru

Сидоров Алексей Викторович, руководитель проектов, АО «ВНИИЖТ», Москва, Россия,

E-mail: Sidorov.Alexey@vniizht.ru

АННОТАЦИЯ

Эта работа открывает серию исследований, объясняющих необходимость и возможность прогрессивной диагностики технического состояния железнодорожного подвижного состава, и предлагает принципиально новое решение этой проблемы на основе современного интеллектуального алгоритма глубокого обучения. Здесь сформирована абстрактная концепция аномальности данных, дана формальная математическая постановка задач поиска и прогнозирования отказов промышленного оборудования, описаны основные компоненты программной реализации решения этих задач с применением модели рекуррентной нейросети (LSTM-автоэнкодера), а также приведены оценка качества работы и аргументация в пользу выбора глубокого обучения среди актуальных методов в области искусственного интеллекта.

Ключевые слова: искусственный интеллект, нейросеть, прескриптивная аналитика, аномалия, отказ, железнодорожный подвижной состав

APPLICATION OF DEEP LEARNING FOR ROLLING STOCK FAILURE PREDICTION

Aleksey V. Komisarchuk, system architect, M.Sc., Railway Research Institute, Moscow, Russia,

E-mail: komisarchuk.aleksei@vniizht.ru

Igor A. Eliseev, department chief, cand. sci. (eng.), Railway Research Institute, Moscow, Russia,

E-mail: eliseev.igor@vniizht.ru

Aleksey V. Sidorov, project manager, Railway Research Institute, Moscow, Russia,

E-mail: Sidorov.Alexey@vniizht.ru

ABSTRACT

This paper begins a series of publications, making a case and opportunity for creation of advanced diagnostics of technical condition of the railway rolling stock and provides essentially new artificial intelligence (AI) solution based on deep learning techniques. Here, the abstraction for anomalous data is formed, statements of industrial equipment failure detection and forecasting problems are set, core components of software implementation of the solution algorithm using the recurrent network (LSTM autoencoder) are described as well as the quality assessments and the reasoning for choosing deep learning over the rest AI methods.

Keywords: artificial intelligence, neural network, long short-term memory, prescriptive analytics, anomaly, failure, railway rolling stock

Введение

Промышленное оборудование зачастую работает в режиме непрерывного цикла, поэтому каждый его критический сбой (авария, отказ) – это существенные экономические потери. Срыв сроков, резкий рост затрат на восстановление работоспособности промышленного оборудования влияют на доходность и стабильность бизнеса. Исключением не является и железнодорожный транспорт, где весь подвижной состав (тяговый и не тяговый) является сложной технической системой. Обеспечение бесперебойной работы оборудования тягового подвижного состава является одной из приоритетных задач в ОАО «РЖД». Задержка поездов на линии из-за отказа оборудования влечет за собой прямые убытки (ремонт, простой) и косвенные (упущенная выгода, штрафы, репутационный ущерб). Не вовремя обнаруженный отказ в оборудовании подвижного состава в процессе ТО или ТР ведет к перебоям в движении на всем участке. Например, в пригородном пассажирском движении – это может быть настолько существенно, что «невыход» поезда на линию может оказаться выгоднее, чем простой в результате потенциальной аварии. Таким образом, сбой в работе подвижного состава является существенным фактором, который может поставить под угрозу всю бизнес-модель перевозок.

Большинство сбоев не случайны, а являются результатами физических процессов, поэтому их можно предсказать и предотвратить, анализируя техническое состояние системы.

Далеко не все можно выявить регулярным техническим обслуживанием, а существующая диагностика крайне ограничена: она не позволяет строить содержательные прогнозы и выявлять дефекты в системе заранее.

Возникновение и развитие неисправностей во многих случаях сопровождается изменениями поведения соответствующих сигналов и, если обнаружить это заранее, то наступление отказа можно предсказать, чтобы успеть принять решение. Долгое время область анализа сигналов ограничивалась методами XX века; инструмента, подходящего для анализа больших данных, не было, особенно в эксплуатации на борту.

Внедрение цифровых систем управления и микропроцессорной техники на подвижном составе позволило получить необходимые вычислительные мощности, на которых теперь можно в реальном времени получать и обрабатывать большие объемы информации о техническом состоянии подвижного состава.

Создание программного решения для его диагностирования, реализованного на вычислительных мощностях информационно-управляющих систем подвижного состава, позволит перейти от решения задач класса «что произошло и каковы причины» к задачам класса «что делать». Для успешного решения последнего класса задач необходимо научиться прогнозировать поведение системы. Это позволит повысить живучесть системы или, другими словами, коэффициент технической готовности подвижного состава, а, следовательно, экономическую эффективность его эксплуатации.

Основной целью данной работы является первичное теоретическое, а также практическое обоснование применимости методов машинного обучения (и нейросетей, в частности) для решения ряда подобных задач, а также описание архитектуры общего решения.

В первых двух частях статьи рассматривается природа данных и недостатки существующих методов диагностики, затем (в части 3) задача диагностики сводится к нескольким задачам машинного обучения, далее предлагается программное решение одной из них (структура описана в части 4). В последней части мы оцениваем результаты и предлагаем альтернативный способ решения оставшейся задачи с помощью уже достигнутого, а также проводим полезную аналогию с другими областями глубокого обучения.

1. Техническая постановка задачи

Динамическое состояние сложной мультифизической системы (такой как поезд, реакторная установка) описывается множеством сигналов различной природы, которые проходя через аналогово-цифровые преобразователи и концентраторы регистрируются

в виде данных в информационно-управляющей системе. Эти данные могут быть использованы для функционирования различных алгоритмов диагностирования локомотива или моторвагонного подвижного состава.

2. Прямые алгоритмы

Простейшие алгоритмы самодиагностирования некоторых подсистем обеспечивают проверку соблюдения некоторых правил в каждый момент времени: соответствие сигнала диапазону значений или теоретическому остаточному ресурсу до плановой замены детали. Более сложные алгоритмы включают математические модели, описывающие физические законы в виде систем алгебраических и дифференциальных уравнений и оценивают степень отклонения результатов измерений реальных параметров с выходными параметрами такой модели. Так, например, модели некоторых узлов поезда ЭС2Г создавались на специальном языке Modelica [10] в проприетарной среде разработки Amesim. Это множество существующих алгоритмов диагностирования назовем прямыми алгоритмами.

У них есть ряд недостатков:

1. Ограниченность. Каждый из таких алгоритмов учитывает в работе крайне небольшое число параметров в отрыве от всех остальных, имеющих в наличии в системе управления. В целом, это проявление более фундаментальной проблемы, заключающейся в том, что данные телеметрии собираются, но почти никак не анализируются.
2. Ad-hoc разработка. Отсутствие универсального подхода к разработке алгоритмов. Каждый алгоритм создается вручную для конкретного узла, что трудозатратно, требует узкой специализации и координации усилий нескольких специалистов, поэтому такие алгоритмы зачастую трудно поддерживать в эксплуатации и масштабировать в будущем.
3. Невозможность прогнозирования состояния по многомерным сигналам. Они позволяют в лучшем случае моделировать линейный тренд отдельного сигнала, что дает условный прогноз его поведения в краткосрочной перспективе, но подходит лишь для очень простых сигналов, а не всего процесса.

Экстенсивный путь развития имеющейся системы (нагромождения разрозненных по подсистемам алгоритмов диагностирования) является тупиковым. Для выхода на другой уровень развития необходима иная стратегия диагностирования технического состояния системы. Она должна базироваться на принципиально новом инструменте, который обладал бы такими качествами:

1. Выявление отклонений в техническом состоянии работы оборудования для предсказания сбоев или отказов на ранней стадии развития дефекта.
2. Универсальность (масштабируемость): разрабатываемый алгоритм должен быть применим не только для одного конкретного поезда, а в целом для любой подвижной железнодорожной единицы с информационно-управляющей системой.
3. Полнота – учет всех измеряемых сигналов, которые прямо или косвенно отражают состояние системы или окружающей среды.
4. Автоматизация – минимизация настроечных параметров алгоритма.
5. Возможность локализации неисправности.
6. Наглядность причинно-следственных связей для обнаружения неочевидных конструктивных дефектов для учета в будущих разработках.

Наделенные такими качествами алгоритмы позволят решать задачи прескриптивной (предписывающей) аналитики – задачи класса «что делать»?

В основу решения задач такого класса, обычно закладываются алгоритмы, основанные на прескриптивной аналитике. Такие алгоритмы учитывают в себе модели искусственного интеллекта и машинного обучения. Они позволяют анализировать разнообразные сценарии

работы оборудования и выбирать наилучшие решения по критерию безопасности и эффективности эксплуатации подвижного состава.

3. Формальная задача машинного обучения

Пусть заданы два множества: объекты X (вопросы) и целевая переменная Y (ответы).

Пусть между ними есть неизвестная зависимость $f: X \rightarrow Y$, которую нужно найти, зная лишь конечное множество пар, называемое обучающей выборкой D (или датасетом):

$$D := \{(x_i, y_i) \mid x_i \in X, y_i \in Y\}_{i=1}^N$$

Каждый алгоритм машинного обучения предлагает свое семейство допустимых отображений, называемое пространством гипотез,

$$H := \{\hat{f}(x): X \rightarrow Y\}$$

Процесс выбора «лучшего» кандидата f^* в таком семействе H и есть машинное обучение.

Это удобно представлять, как аппроксимацию функций, обобщением которой оно и является. Впрочем, теперь отображение \hat{f} может вообще не иметь функциональной формы. Это стандартная постановка задачи машинного обучения, все прочие так или иначе сводятся к ней. Иногда она называется обучением с учителем (*supervised learning*).

Задачи без заданного Y иногда называются обучением без учителя (*unsupervised learning*) и легко приводятся к стандартному виду (выше) выбором $Y = X$. К примеру, такой является задача сжатия (снижения размерности) данных, рассматриваемая в этой статье.

Для оценки кандидатов на H вводится функционал качества,

$$Q(\hat{f}): H \rightarrow R$$

и машинное обучение сводится к его оптимизации на H по некоторому критерию. Без ограничения общности, можно ввести функционал ошибки,

$$\mathcal{L}(\hat{f}) := Q(\hat{f}): H \rightarrow R^+ \cup \{0\}$$

и взять его минимизацию в качестве критерия оптимальности,

$$\min_{\hat{f} \in H} \mathcal{L}(\hat{f})$$

Две популярные в алгоритмах функции потерь — это реализации функционала ошибки,

$$L_1(\hat{f}_\theta) := \sum_{(x,y) \in D} |\hat{f}(x, \theta) - y|$$

$$L_2(\hat{f}_\theta) := \sum_{(x,y) \in D} (\hat{f}(x, \theta) - y)^2$$

Первая, L_1 также называется средней абсолютной ошибкой (*mean average error, MAE*) и мы именно ее будем использовать далее в алгоритме.

В случае, если речь идет о параметрическом семействе (функций),

$$H = \{\hat{f}_\theta(x): X \rightarrow Y\}_{\theta \in \Theta}$$

задача оптимизации на H сводится к задаче оптимизации на пространстве параметров Θ ,

$$\min_{\hat{f} \in H} \mathcal{L}(\hat{f}) = \min_{\theta \in \Theta} \mathcal{L}(\hat{f}(x, \theta))$$

Например, нейросеть определяет некоторую функцию параметрически и её обучение – это оптимальная настройка набора параметров $\theta \in \Theta$ на обучающей выборке D .

Действительно, задача машинного обучения для нейросети может быть сформулирована следующим образом:

$$H = \{\hat{f}_\theta(x): X \rightarrow Y = X\}_{\theta \in \Theta}, \quad X \subset R^n$$

сводится к минимизации функции потерь (LI) на пространстве параметров нейросети \hat{f} ,

$$\min_{\theta \in \Theta} \mathcal{L}(\hat{f}(x, \theta)) = \min_{\theta \in \Theta} \sum_{(x,y) \in D} |\hat{f}(x, \theta) - y|$$

4. Аномалии и решение задачи их поиска

На словах отказ понимается как необратимое критическое состояние системы, но это наше субъективное представление нужно формализовать и передать в алгоритм. Это можно сделать, создав размеченный (с примерами отказов) датасет для обучения,

$$X \subset R^n, \quad Y = \{0,1\} \cong \{\text{норма, отказ}\} \quad (1)$$

Итак, с теоретической точки зрения, детекция отказов – это задача бинарной классификации (1). Данные телеметрии – это просто объекты X без пар, они не позволяют использовать методы машинного обучения с учителем, но вполне подходят для алгоритмов обучения без учителя и можно рассмотреть другой подход. Прежде всего, абстрагируемся от отказов, которые невозможно объективно формализовать и рассмотрим более широкое понятие – аномальность.

Аномалия – это последовательность точек, которые настолько выделяются [1] среди остальных данных, что возможен иной механизм их возникновения (ненормальный ход процесса, например, возникшая неисправность или внешнее воздействие).

Отсюда прямо следует, что:

- любое определение аномалии всегда относительно (нормы), ведь неявно определяет норму как некое господствующее поведение системы;
- для выявления аномалий крайне важно окружение точек (порядок и контекст); точки сами по себе (изолированные) ничего не значат.

На рисунке 1 наряду с нормальными формами сигналов показаны некоторые примеры различных аномалий одномерного сигнала: цветом выделены выбросы (фиолетовый), аперриодичность (красный), нарушение волатильности (зеленый).

В многомерном случае, точке в пространстве соответствует вектор значений нескольких переменных. Аномалия, связывающая несколько сигналов сразу, называется многомерной (многоканальной). Необходимо отметить, что это не то же самое, что множество одновременных одномерных аномалий и вполне может существовать, даже если по отдельности все сигналы в норме. В общем случае, она устроена сложно, ее непротиворечивая визуализация невозможна и можно лишь определить ее границы. Ее практически невозможно найти вручную, но для этого можно использовать нейронные сети.

Большинство аномалий бесследно исчезают и вообще не приводят к сиюминутному отказу. Отказ – это просто одна из множества аномалий, особая лишь для диагностирования.

В силу субъективности, выделить именно отказы среди остальных аномалий практически невозможно. В данной публикации ограничимся рассмотрением задачи поиска аномалий на неразмеченных данных, методы машинного обучения позволяют это сделать.

Суть предлагаемого алгоритма в том, что, считая, что норма – это основное состояние системы, мы будем моделировать нормальное поведение физических процессов, а аномалии будут найдены как существенные отклонения от него.

В результате рассмотрения преимуществ и недостатков различных подходов к моделированию, нейросеть была выбрана как лучший и единственный на данный момент универсальный подход к автоматизированному моделированию сложного многомерного процесса.

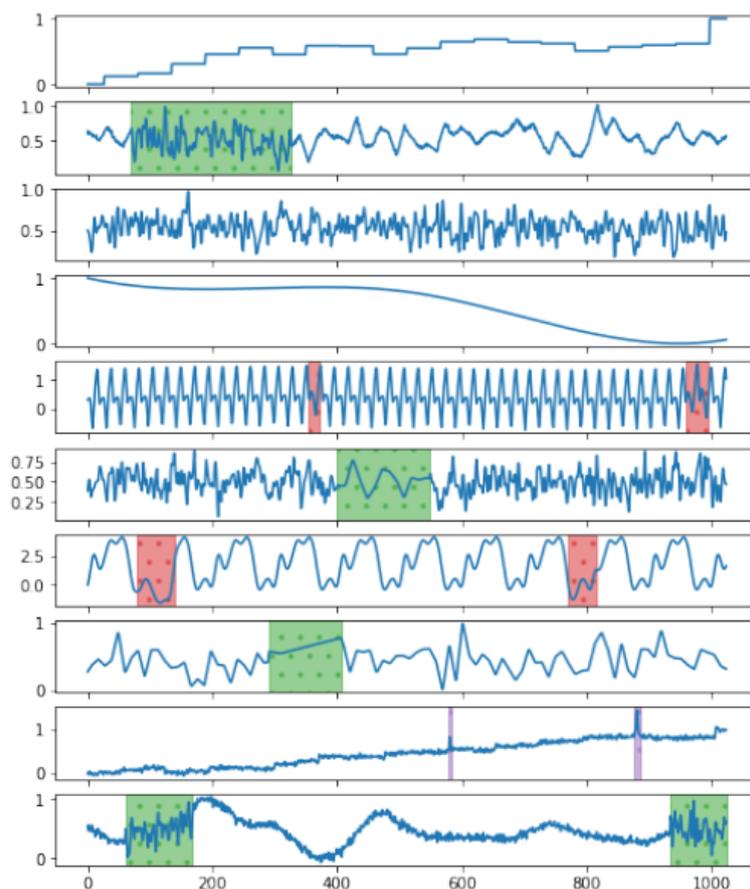


Рис. 1 – Цветом выделены примеры различных аномалий одномерных сигналов

Для того, чтобы оценить аномальность i -параметра, мы вводим метрику, которая сравнивает MAE на интересующем нас (*control*) периоде со всем предшествующим периодом (*past*) и коэффициент аномальности рассчитывается так:

$$AC(i) = \frac{MAE_{control}(i)}{MAE_{past}(i)}$$

Усреднение здесь происходит по каждому параметру независимо. Если модель была хорошо обучена, высокое значение коэффициента свидетельствует о ненормальном развитии процесса. Выбирая порог для каждого сигнала, разработчик настраивает чувствительность модели. Кроме этого, с помощью базовых ошибок этой модели можно автоматически создать предварительную разметку датасета для решения задачи обучения с учителем.

Есть два ключевых ограничения, определяющих архитектуру нейросети:

1. Для того, чтобы заставить нейросеть эффективно выявлять закономерности, а не запоминать и повторять данные, нужна структура слоев с «бутылочным горлышком», называемая автоэнкодером. Другими словами, перед нами встает задача сжатия данных X (с потерями) в латентное пространство меньшей размерности с качественными (отражающими физику процесса) признаками.
2. Для того, чтобы определять сложные аномалии (в контексте), нейросеть должна уметь работать с последовательностями. Для начала, можно взять рекуррентные [2] слои с *LSTM*-ячейками [3], обладающими кратко- и долгосрочной памятью. Кроме

всего прочего, у них есть уникальная особенность – умение работать с (условно) бесконечными последовательностями.

Итак, в качестве отправной точки была взята архитектура рекуррентного автоэнкодера (RAE). Отметим, что существует [4-6] сразу несколько его разновидностей; конкретная реализация, описанная здесь, похожа на них лишь отдаленно; ее структурная схема представлена на рисунке 2 ниже:

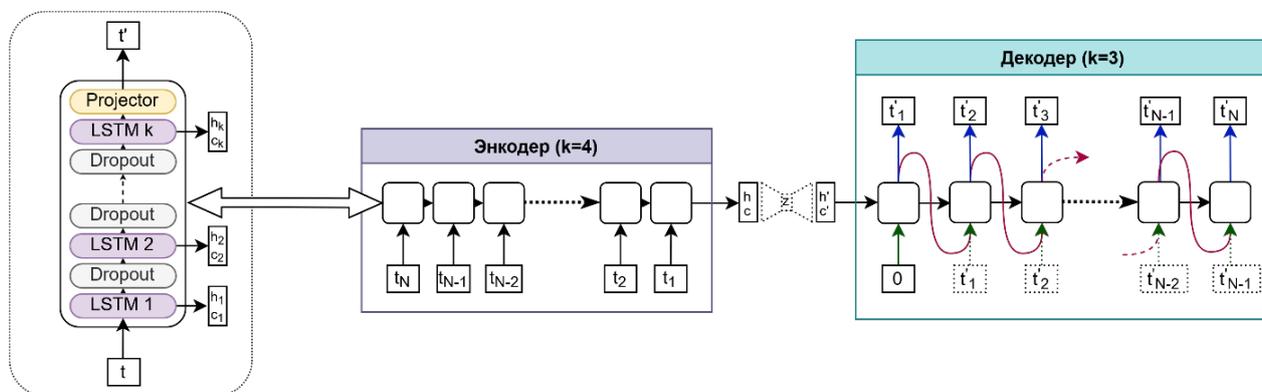


Рис. 2 – Структурная схема модели НС (RAE) и ее характеристики

Если представить, что последовательность состояний системы на входе – текст, можно увидеть аналогию нашей задачи с задачей машинного перевода текстов в области обработки естественных языков (NLP). Это не случайность и наша модель напоминает Seq2Seq-модели [4] для анализа текстов. Можно ускорить разработку, перенести лучшие решения оттуда на наш домен, например, архитектуру трансформеров [9] в семействе больших языковых моделей LLM.

Исходные данные представляют собой массив данных сигналов телеметрии произвольного размера и в таком «сыром» виде не подходят для обучения нейросети, требуется их существенная предобработка: из них формируется специально структурированный двумерный массив данных, подаваемых на вход для обучения нейросетевой модели парами (датасет). Создание собственного датасета всегда представляет значительную сложность, наша задача не является исключением.

В Таблице 1 видно, что на вход наша модель принимает двумерный тензор размерности (100, 1807), а на выходе ожидает тензор размерности (100, 1337):

Таблица 1

Характеристики используемой модели

Наименование характеристики	Тензор размерности
Длина входной последовательности	100
Длина выходной последовательности	100
Количество входных признаков	1807
Количество выходных признаков	1337
Латентная размерность	333
Число (рекуррентных) слоев	7
Число параметров	13М

В результате, решение нашей задачи было разделено на пять этапов:

1. Получение данных.
2. Анализ и предобработка данных.
3. Моделирование с помощью нейросети (RAE).

4. Оценка аномальности (метрика).

5. Визуализация результатов.

Они реализованы независимо и исполняются последовательно, напоминая конвейер, изображенный на рисунке 3 ниже:

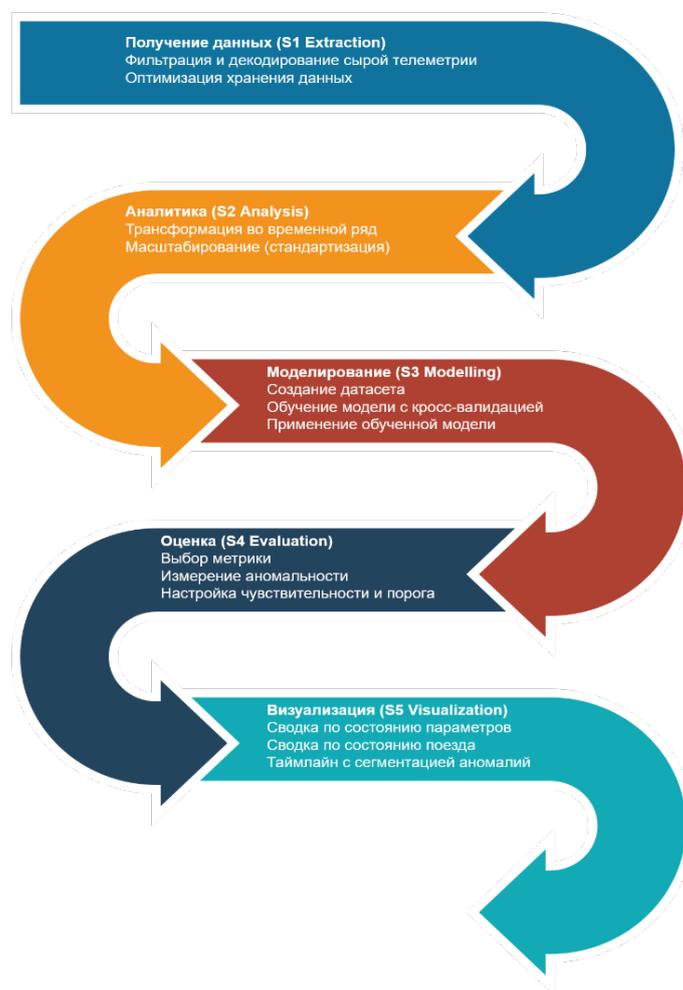


Рис. 3 – Иллюстрация «конвейера данных» с этапами обработки

Процесс обработки данных на борту подвижного состава полностью автоматизирован с помощью протокола информационного обмена. Для промежуточного хранения данных между этапами был выбран иерархический файловый формат *HDF5*, а также разработаны средства для упаковки (архивирования) в него различных метаданных, сопровождающих вычисления. В результате, каждый такой файл содержит информацию, необходимую для следующего этапа обработки.

Это – одно из правил нашего системного дизайна, которое позволяет вести параллельную разработку каждого этапа, а, следовательно, сокращает сроки реализации проекта.

5. Алгоритм обучения и оценка результатов

В качестве функции потерь выбрана *L1 (MAE)*, алгоритм ее оптимизации при обучении – *Adam* с начальным шагом $LR=0.001$ и стратегией снижения шага обучения при отсутствии улучшений на валидации (*ReduceLROnPlateau* в *Pytorch*).

Модель решает задачу регрессии, поэтому ключевой метрикой эффективности обучения является ошибка *MAE*, измеряемая на небольшой (10% от всей) отложенной (валидационной)

выборке, которая исключается из данных для обучения.

За 60 эпох обучения эта метрика уменьшилась в 5 раз (Таблица 2) и этот результат достаточно устойчив, что позволяет говорить о том, что модель в первом приближении решает задачу. Дальнейшее совершенствование требует аккуратного подбора гиперпараметров и длительного обучения на подготовленных качественных данных.

Таблица 2

Характерное снижение ошибки (MAE) моделирования на обучающей и валидационной выборках

Epoch	MAE(Train)	MAE(Val)
1	1.18	1.22
10	1.05	1.09
20	0.92	0.94
30	0.74	0.79
40	0.48	0.55
50	0.20	0.32
60	0.13	0.21
70	0.09	0.23

Заметим, что низкая ошибка *MAE* означает, что разработанный алгоритм позволяет достаточно хорошо моделировать 1337 параметров на выходе на протяжении 100 секунд (в каждую секунду). На рисунке 4 представлены один из них (бирюзовый) и предсказание его поведения на 100 секунд вперед (малиновый) на валидационной выборке моделью, а также построен график ошибки *MAE*.

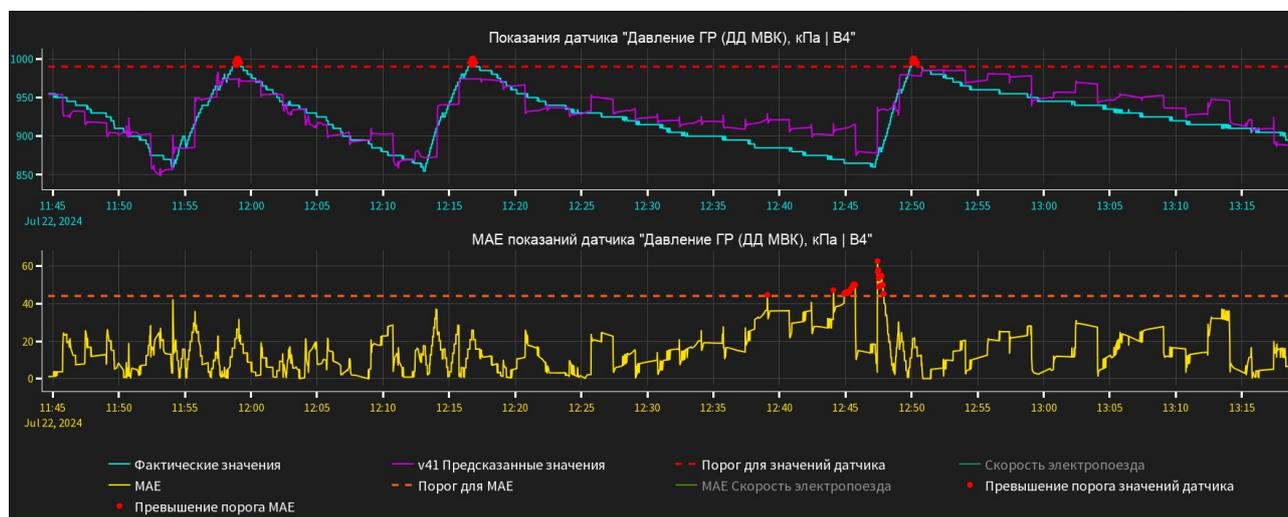


Рис. 4 – Результаты моделирования (v41-идентификатор модели) давления в главном резервуаре в прототипе интерфейса для визуализации (система АИСТ)

Кроме того, отсюда следует, что 1337*100 чисел на входе описываются всего 333 значениями (в Таблице 1 – размерность латентного пространства модели), что означает наличие более простой структуры в реальных данных. На самом деле, это – проявление общей закономерности [8], связанной с тем, что данные получены в ходе реального физического процесса.

Используя авторскую модель в системе ПСД (прескриптивная система диагностики, разработка АО «ВНИИЖТ») был найден сбой в работе системы ПСН (преобразователь

собственных нужд – это инвертор, который преобразует ток высокого напряжения в низкие напряжения для питания различных вспомогательных систем поезда ЭС2Г), который для проверки работы модели был нагружен искусственно (в ходе испытаний). На рисунке 5 ниже заметно, как инвертор был загружен, но эта мощность не питала штатные системы поезда (оборудованные датчиками) и потому проявилась как аномалия.

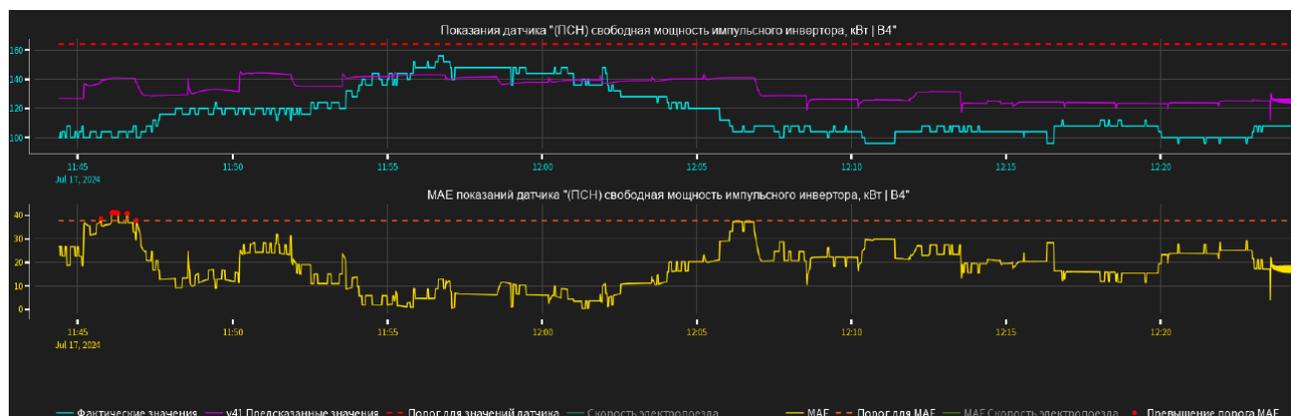


Рис. 5 – Иллюстрация аномалии в показаниях свободной мощности ПСН, найденной в период с 11:45 до 11:47, свидетельствующей об ограничении доступной мощности ПСН

Для решения следующей задачи (предсказания отказов) эффективнее сразу работать с новым, компактным признаковым описанием (z) вместо оригинальных данных. На рисунке 6 показана связь этих двух задач.



Рис. 6 – Иллюстрация связи задачи поиска аномалий с задачей прогнозирования отказов при помощи трансферного обучения

Возьмем только обученный энкодер (E) модели и зафиксируем его веса, а остальное заменим на нейросеть-классификатор (C), выдающую вероятность отказа с последующим её обучением (см. рисунок 5). Это называется [7] трансферным обучением (*Transfer learning*).

Именно так и надо решать задачу предсказания отказов, потому что, если данные для нее размечены, но их мало, обучать модель для предсказания отказов напрямую нерационально: качество будет низким. Об этом будет подробно изложено в одной из следующих публикаций.

Заключение

В ходе данного исследования, реальная проблема предсказания отказов и поиска аномалий обрела формализованную математическую постановку в виде задачи оптимизации на примере оценки технического состояния электропоезда ЭС2Г.

Среди различных алгоритмов машинного обучения было найдено и теоретически обосновано уникальное решение на основе нейросети для поиска аномалий в больших данных. С его помощью были исследованы данные с электропоезда, которые, несмотря на существенные проблемы с качеством, были хорошо описаны предложенной архитектурой модели RAE.

Реализованный подход в системе ПСД (прескриптивная система диагностики, разработка АО «ВНИИЖТ») помог найти сбои в системе ПСН моторвагонного подвижного состава, созданные искусственно в ходе испытаний.

Найденное решение поиска аномалий в поведении сигналов, характеризующих работу подвижного состава, положено в основу решения задачи предсказания отказов.

Разработанный алгоритм и модель RAE обеспечивают автоматизацию разметки предотказного состояния и формирование классификатора отказов.

В будущем, предлагается усовершенствовать математическую модель НС и алгоритм аналитики, используя подходы [9] из области NLP, продолжить поиск лучших архитектур нейросети, оптимизацию гиперпараметров и совершенствование статистических метрик аномальности.

Список использованной литературы

1. D. Hawkins, *Identification of Outliers*. London: Chapman and Hall, 1980
2. J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities,” *Proc. Nat. Acad. Sci. U.S.A.*, vol. 79, no. 8, pp. 2554–2558, 1982.
3. S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
4. N. Srivastava, E. Mansimov, and R. Salakhutdinov, “Unsupervised Learning of Video Representations using LSTMs,” in *Proc. Int. Conf. Mach. Learn. (ICML)*, 2016, pp. 843–852.
5. J. F. Kolen and S. C. Kremer, *A Field Guide to Dynamical Recurrent Networks*. New York: Wiley-IEEE Press, 2001.
6. I. Sutskever, O. Vinyals, and Q. V. Le, “Sequence to Sequence Learning with Neural Networks,” in *Adv. Neural Inf. Process. Syst. (NIPS)*, 2014, pp. 3104–3112.
7. A. Sagheer and M. Kotb, “Unsupervised pre-training of a deep LSTM-based stacked autoencoder for multivariate time series forecasting problems,” *Sci. Rep.*, vol. 9, p. 19038, 2019.
8. N. Whiteley, A. Gray, and P. Rubin-Delanchy, “Statistical exploration of the Manifold Hypothesis,” *J. Amer. Stat. Assoc.*, 2025. (Early Access).
9. A. Vaswani et al., “Attention is all you need,” in *Adv. Neural Inf. Process. Syst. (NIPS)*, 2017, pp. 5998–6008.
10. K. Besbes et al., “Sizing of an electric powertrain using a hybrid model combining Simcenter Amesim and Modelica components,” in *Proc. IEEE Veh. Power Propuls. Conf. (VPPC)*, 2020, pp. 1–6.

УДК 004.89

СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ УПРАВЛЕНИЯ ВОЗВРАТАМИ В ЭЛЕКТРОННОЙ КОММЕРЦИИ НА ОСНОВЕ АЛГОРИТМА ДОЖДЕВЫХ ЧЕРВЕЙ И НЕЧЕТКОГО СЛУЧАЙНОГО ЛЕСА

Борисов Вадим Владимирович, д.т.н., профессор, филиал ФГБОУ НИУ «МЭИ» в г. Смоленске, Смоленск, Россия, E-mail: vbor67@mail.ru

Булугина Ольга Валентиновна, к.э.н., доцент, филиал ФГБОУ НИУ «МЭИ» в г. Смоленске, Смоленск, Россия, E-mail: baguzova_ov@mail.ru

Зубарева Виктория Николаевна, студент, филиал ФГБОУ НИУ «МЭИ» в г. Смоленске, Смоленск, Россия, E-mail: zubarvikaaa@mail.ru

АННОТАЦИЯ

Статья посвящена исследованию возможностей применения методов интеллектуального анализа данных и биоинспирированных алгоритмов оптимизации при управлении возвратами товаров в электронной коммерции. В работе предлагается архитектура системы поддержки принятия решений (СППР), ориентированной на решение задач многокритериальной оптимизации возвратных маршрутов и классификацию причин возвратов. Показано, что применение биоэвристики позволяет формировать устойчивые и сбалансированные маршруты с учётом расстояния, времени и сложности логистической сети, а использование нечеткого случайного леса обеспечивает интерпретируемый анализ субъективных и неполных клиентских данных. Предложенная архитектура СППР демонстрирует высокую гибкость, масштабируемость и возможность интеграции с логистическими платформами и *WMS*-системами, обеспечивая комплексную поддержку процессов анализа возвратных потоков. Рассмотрена экономическая эффективность внедрения системы, включающая снижение логистических затрат, уменьшение числа необоснованных возвратов и повышение качества клиентского сервиса.

Ключевые слова: алгоритм дождевых червей, нечеткий случайный лес, система поддержки принятия решений, возвратная логистика, электронная коммерция, многокритериальная оптимизация, интеллектуальный анализ данных.

DECISION SUPPORT SYSTEM FOR MANAGING RETURNS IN E-COMMERCE BASED ON THE EARTHWORM ALGORITHM AND FUZZY RANDOM FOREST

Vadim V. Borisov, Doctor of Technical Sciences, Professor, Smolensk branch of Moscow Power Engineering Institute, Smolensk, Russia, E-mail: vbor67@mail.ru

Olga V. Bulygina, Candidate of Economics, Associate Professor, Smolensk branch of Moscow Power Engineering Institute, Smolensk, Russia, E-mail: baguzova_ov@mail.ru

Victoria N. Zubareva, student, Smolensk branch of Moscow Power Engineering Institute, Smolensk, Russia, E-mail: zubarvikaaa@mail.ru

ANNOTATION

The article is devoted to the study of the possibilities of using intelligent data analysis methods and bioinspired optimization algorithms in the management of returns in e-commerce. The paper proposes the architecture of a decision support system (DSS) that combines an earthworm algorithm for multi-criteria optimization of return routes and a fuzzy random forest for classifying the causes of returns. It is shown that the use of bioheuristics makes it possible to form stable and balanced routes taking into account the distance, time and complexity of the logistics network, and the use of a fuzzy random forest provides an interpretable analysis of subjective and incomplete customer data. The proposed DSS architecture demonstrates high flexibility, scalability, and the ability to integrate with logistics platforms and *WMS*, providing comprehensive support for return flow analysis. The economic efficiency of the implementation of the system is considered, including reducing logistical costs, reducing the number of unjustified refunds and improving the quality of customer service.

Keywords: earthworm algorithm, fuzzy random forest, decision support system, return logistics, e-commerce, multi-criteria optimization, intelligent data analysis.

Введение

Рост объёмов электронной коммерции сопровождается увеличением количества возвратов, что приводит к существенным затратам для торговых платформ, логистических операторов и производителей [1]. Управление возвратами является сложным процессом, связывающим задачи классификации причин возврата и оптимизации логистических маршрутов. Традиционные методы анализа данных часто оказываются недостаточно эффективными из-за значительной неопределённости в пользовательской информации, а классические алгоритмы маршрутизации не всегда обеспечивают достаточную адаптивность при изменении условий.

Современные методы интеллектуального анализа данных и биоинспирированные алгоритмы оптимизации открывают новые возможности для разработки систем поддержки принятия решений (СППР), ориентированных на решение задач многокритериальной оптимизации маршрутов возвратов и классификацию их причин.

Целью данной статьи является разработка архитектуры СППР, в которой алгоритм дождевых червей применяется для построения рационального возвратного маршрута, а нечеткий случайный лес – для классификации причин возврата товаров.

1. Применение алгоритма дождевых червей для оптимизации маршрутов возврата товара в электронной коммерции

Современная логистика возвратов в электронной коммерции характеризуется высокой вариативностью условий, ростом объёмов обратных поставок и необходимостью учитывать несколько противоречивых критериев при выборе оптимального маршрута. Одновременно минимизировать затраты, время транспортировки и маршрутную сложность невозможно, что приводит к необходимости искать компромиссные решения. Задача построения рациональных маршрутов возвратов товаров в электронной коммерции относится к классу комбинаторных оптимизационных задач, в частности, к обобщениям задачи коммивояжёра (*Traveling Salesman Problem, TSP*) с дополнительными ограничениями и несколькими критериями оптимальности.

К настоящему моменту предложено значительное количество методов решения подобных задач. К классическим подходам относятся точные методы математического программирования, включая целочисленное линейное программирование, методы ветвей и границ, а также динамическое программирование. Несмотря на их теоретическую строгость, данные методы применимы лишь к задачам малой размерности, поскольку вычислительная сложность резко возрастает при увеличении числа узлов и критериев оптимизации. В условиях реальных логистических сетей электронной коммерции, характеризующихся высокой размерностью и изменчивостью параметров, использование точных методов оказывается практически невозможным.

В связи с этим в последние годы в мировой и отечественной научной практике широкое распространение получили метаэвристические алгоритмы, в частности алгоритмы имитации отжига (*Simulated annealing, SA*) [2], муравьиной колонии (*Ant Colony Optimization, ACO*) [3] и роя частиц (*Particle Swarm Optimization, PSO*) [4]. Указанные методы активно применяются для решения задачи коммивояжёра и её многокритериальных обобщений, а также задач маршрутизации, в том числе в логистических приложениях. Их ключевым преимуществом является способность эффективно исследовать большие пространства решений без полного перебора, сочетая глобальный поиск и локальное улучшение решений, что подтверждается результатами сравнительного анализа, представленными в [5].

Вместе с тем анализ результатов вычислительных экспериментов показывает, что указанные метаэвристики обладают и рядом ограничений [6]. В частности, алгоритмы имитации отжига и муравьиной колонии демонстрируют чувствительность к выбору параметров и при определённых настройках могут преждевременно сходиться к локальным

экстремумам. Алгоритмы роя частиц, обеспечивая высокую скорость сходимости на начальных этапах поиска, на поздних стадиях часто теряют разнообразие популяции, что снижает качество получаемых решений. Данные особенности подробно проанализированы в упомянутой ранее статье, где показано, что эффективность перечисленных методов при решении задачи коммивояжёра существенно зависит от способности поддерживать баланс между исследованием пространства решений и эксплуатацией найденных маршрутов. В задачах возвратной логистики, характеризующихся высокой размерностью и сложной структурой пространства перестановок, указанные ограничения приобретают принципиальное значение.

В задачах возвратной логистики, где оптимальные маршруты могут существенно различаться по структуре и располагаться в удалённых областях пространства перестановок, данные ограничения приобретают критический характер. В этом контексте перспективным направлением исследований являются новые биоинспирированные алгоритмы, ориентированные на более устойчивый баланс между глобальным и локальным поиском. Одним из таких методов является алгоритм дождевых червей (*Earthworm Optimization Algorithm, EWA*) [7], представляющий собой биоинспирированную метаэвристику, основанную на двух типах воспроизводства дождевых червей и механизмах их регенерации.

Алгоритм дождевых червей основан на биологических особенностях этих организмов, прежде всего на их способности к двум формам «размножения» и к регенерации. В естественной среде дождевые черви выступают гермафродитами, поэтому каждая особь может порождать потомство самостоятельно (данный принцип отражён в механизме *Reproduction 1*). В алгоритме упрощённо считается, что червь может порождать потомка сам, хотя в природе требуется партнёр. В то же время взаимодействие нескольких червей приводит к обмену генетическим материалом и появлению разных вариантов потомков, что моделируется механизмом *Reproduction 2*. Существенным является и то, что многие виды способны восстанавливать утраченные сегменты тела, что аналогично созданию новых решений путём комбинирования параметров предыдущих.

Алгоритм *EWA* реализует популяционную стратегию: набор решений постепенно эволюционирует от поколения к поколению. Первый механизм, *Reproduction 1*, формирует новое решение, опираясь на одного родителя (степень его схожести с исходным экземпляром определяется параметром α). Второй механизм, *Reproduction 2*, задействует несколько родителей, объединяя их свойства через различные типы кроссоверов и генерируя один или несколько промежуточных потомков. Эти потомки затем агрегируются в итоговое решение с учётом весовой схемы, где веса рассчитываются на основании их качественных характеристик, усиливая влияние более перспективных вариантов. Параметр β управляет относительной значимостью двух механизмов размножения и уменьшается от поколения к поколению по закону геометрического затухания, что повышает интенсивность локального поиска. Однако при увеличении β повышается интенсивность глобального поиска. Кроме того, используется мутационный оператор на основе распределения Коши, позволяющий изредка вносить существенные изменения в решение и, тем самым, улучшать исследование пространства.

На рисунке 1 представлена блок-схема алгоритма дождевых червей, отражающая процесс эволюции популяции возможных решений.

Маршруты возврата представляются в виде перестановок промежуточных пунктов, через которые должен пройти возвращаемый товар. Начальная популяция формируется случайным образом, что обеспечивает охват широкого спектра возможных решений и позволяет алгоритму начинать поиск без предварительных ограничений. Задаются параметры α , определяющий интенсивность глобального поиска, и β , отвечающий за баланс между двух механизмов размножения при формировании новой позиции червя.

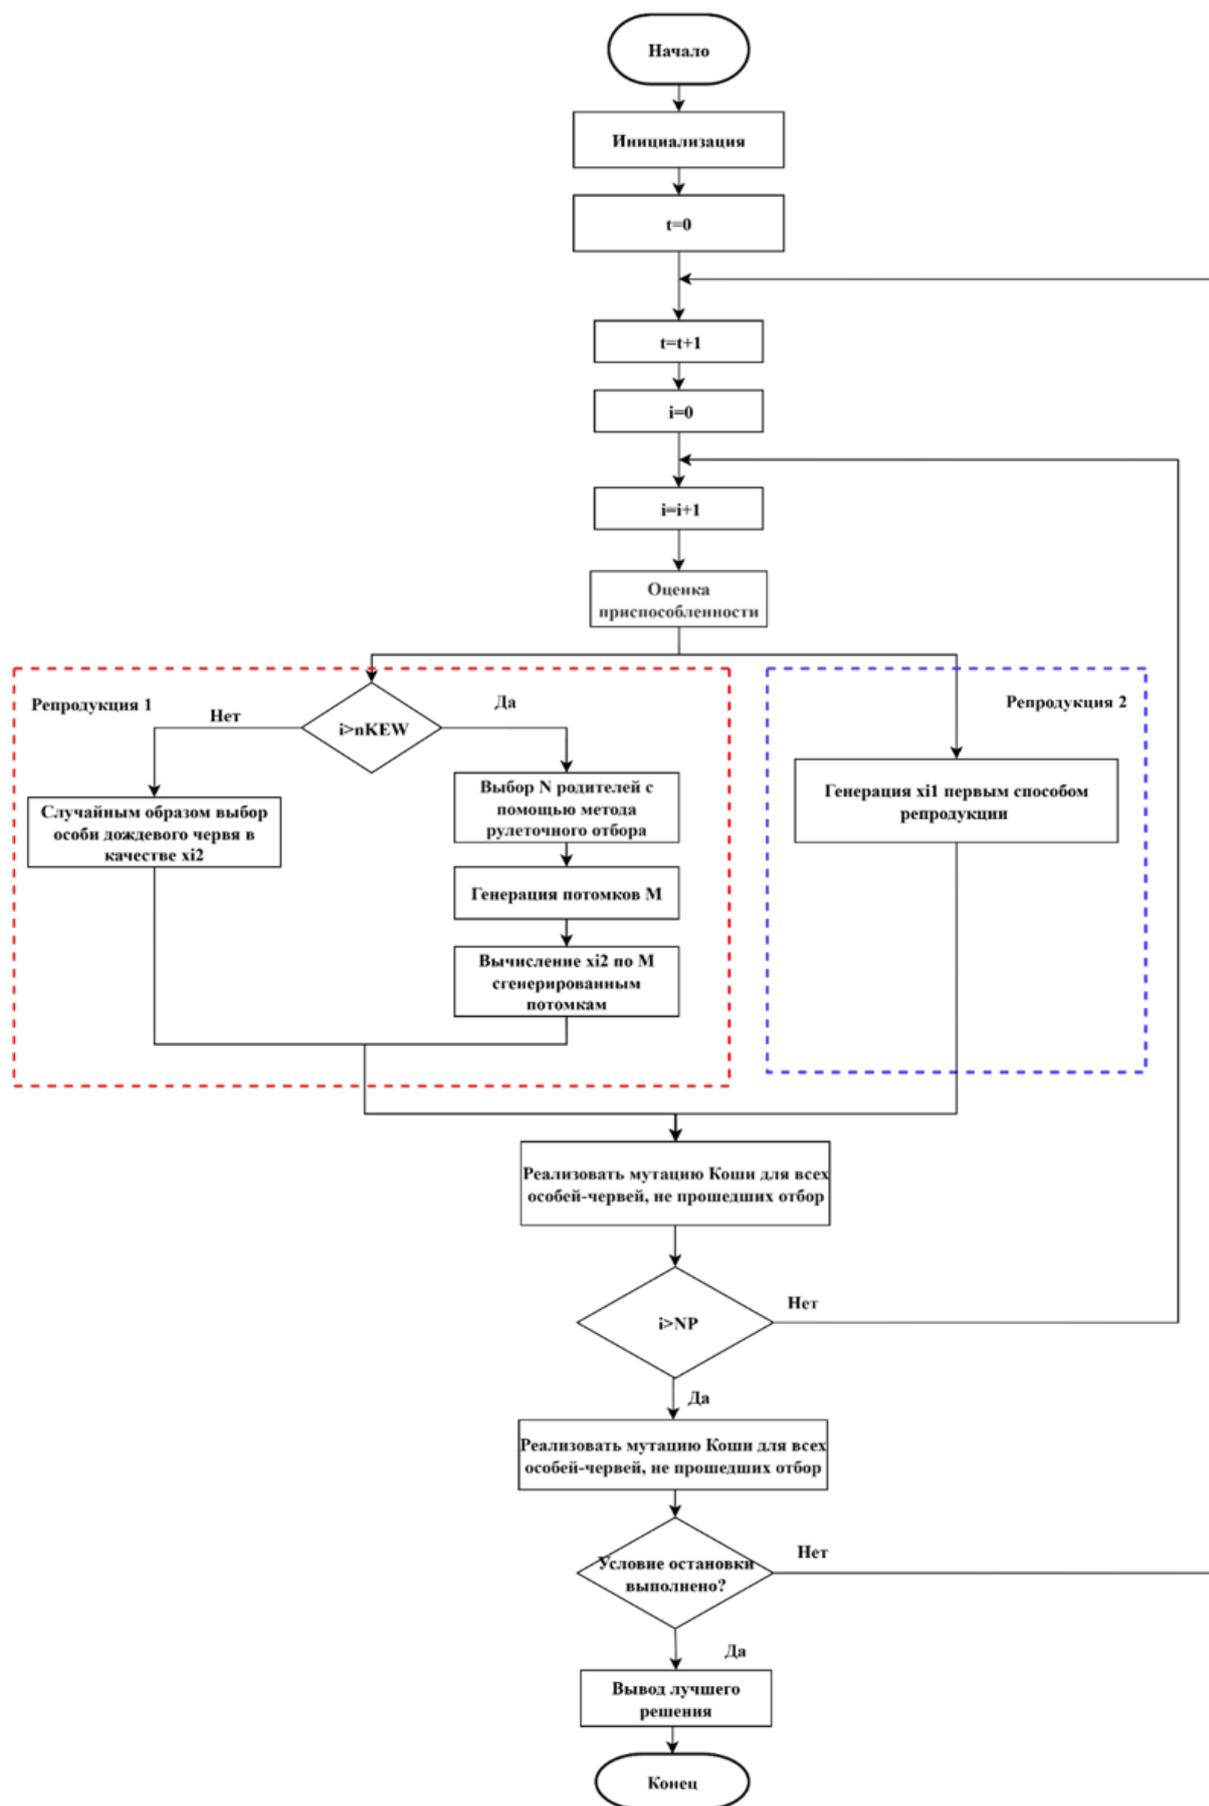


Рис. 1 – Блок-схема биоинспирированного алгоритма дождевых червей

Оценка приспособленности каждого маршрута осуществляется на основе трёх минимизируемых критериев: суммарной длины пути, временных затрат и сложности маршрута, которая отражает состояние дорожной инфраструктуры. Для сравнения альтернатив используется концепция Парето-доминирования, согласно которой маршрут считается недоминируемым, если не существует другого варианта, улучшающего хотя бы один из критериев без одновременного ухудшения остальных. Такие недоминируемые решения формируют Парето-фронт.

Механизм *Reproduction 1* обеспечивает глобальный характер поиска. В нём параметр α определяет степень допустимого отклонения нового решения от исходного маршрута, благодаря чему при больших значениях α алгоритм способен совершать дальние переходы в пространстве решений и избегать преждевременной сходимости.

В *Reproduction 2* задействуется несколько родительских решений, которые порождают новые маршруты посредством различных схем кроссовера. Одновыборочный кроссовер создаёт новое решение за счёт перестановки отдельных частей маршрутов, многоточечный кроссовер позволяет обмениваться несколькими сегментами и формирует более разнообразные структуры, а равномерный кроссовер комбинирует узлы маршрутов покомпонентно. Такой подход способствует объединению перспективных фрагментов из разных родительских маршрутов и формированию более качественных траекторий.

Сформированные результаты объединяются с помощью параметра β , который постепенно уменьшается по мере развития вычислительного процесса. На ранних этапах это обеспечивает широкое исследование пространства, а на поздних происходит усиление локального поиска возле наиболее перспективных решений. Дополнительные адаптивные изменения обеспечиваются мутацией Коши, которая формирует редкие, но существенные модификации маршрутов. Благодаря «толстым хвостам» распределения Коши такие изменения позволяют алгоритму перескакивать в отдалённые области пространства решений и сохранять высокую степень разнообразия.

Завершается работа алгоритма после достижения максимального числа поколений. На этом этапе формируется Парето-фронт, отражающий множество недоминируемых решений, из которого выбираются маршруты, обеспечивающие наилучший баланс между длиной, временем и сложностью прохождения.

Построение рационального маршрута возврата товара между заданными пунктами сводится к задаче многокритериальной оптимизации, в которой требуется минимизировать совокупный показатель качества маршрута.

Пусть маршрут представлен последовательностью городов $X = (x_1, x_2, \dots, x_{15})$, где x_1 – фиксированная начальная точка, а x_{15} – фиксированная конечная точка. Тогда многокритериальная задача формулируется следующим образом:

$$F(X) = (f_1(X), f_2(X), f_3(X)) \rightarrow \min$$

где $f_1(X)$ – суммарное расстояние маршрута (L), $f_2(X)$ – суммарное время прохождения маршрута (T), $f_3(X)$ – показатель сложности или рискованности маршрута (D).

При этом все три критерия подлежат минимизации, а их совместная оптимизация приводит к формированию множества недоминируемых решений, образующих Парето-фронт.

Одним из ключевых факторов, подтверждающих применимость *EWA* в сфере возвратной логистики, является способность алгоритма работать в условиях огромного пространства поиска. Маршрут возврата товара задаётся перестановкой промежуточных пунктов, что приводит к экспоненциальному росту числа возможных решений. Даже при сравнительно небольшом числе узлов, например, 13, получается почти 6,23 миллиардам потенциальных маршрутов. Полный перебор в таких условиях невозможен, а эффективность строгих оптимизационных методов резко падает с ростом размерности задачи. *EWA*, напротив, позволяет быстро находить перспективные решения, не требуя исчерпывающего анализа всех вариантов.

Не менее важна способность алгоритма сочетать глобальное исследование пространства и локальное улучшение найденных решений. Механизм *Reproduction 1* способствует формированию маршрутов, значительно отличающихся от исходных, что позволяет исследовать широкие области пространства решений. *Reproduction 2* ориентирован на локальные улучшения, объединяя сильные стороны нескольких родительских маршрутов и постепенно повышая их качество. Такое сочетание обеспечивает баланс между поиском

новых областей и совершенствованием уже найденных решений, что особенно ценно для логистических задач, где локальные структуры маршрутов могут быть критичны для эффективности доставки.

Особое значение имеет способность *EWA* учитывать противоречивость критериев. В реальных условиях возвратная логистика требует оптимизировать не один показатель, а несколько одновременно: общую протяженность пути, временные затраты и сложность прохождения отдельных участков. Улучшение одного критерия часто приводит к ухудшению другого, поэтому оптимизация приобретает многокритериальный характер. Предлагаемый *EWA* формирует множество Парето-оптимальных маршрутов, демонстрирующих различные компромиссы между расстоянием, временем и сложностью. Это обеспечивает гибкость при выборе наиболее подходящего решения с учётом конкретных логистических условий и ограничений.

Важным элементом алгоритма является мутационный оператор, основанный на распределении Коши. Он генерирует редкие, но значительные изменения маршрутов, что позволяет алгоритму избегать застревания в локальных минимумах и поддерживать разнообразие популяции [8]. Такое свойство особенно полезно в задачах маршрутизации, где качественные решения нередко расположены далеко друг от друга в пространстве перестановок.

В контексте логистики возвратов алгоритм дождевых червей способен моделировать широкий спектр возможных условий, охватывая различные конфигурации транспортной сети. При формировании матриц расстояний, времени и сложности *EWA* может анализировать большое количество альтернативных маршрутов и выявлять варианты, обеспечивающие наилучший баланс между ключевыми логистическими показателями. Это делает его эффективным инструментом для поддержки принятия решений при планировании возвратных логистических потоков.

Алгоритм способен последовательно улучшать качество решений, переходя от широкого исследования пространства на ранних этапах к локальному поиску вблизи наиболее перспективных маршрутов. Такая динамика позволяет оценивать структуру пространства решений, выявлять области с высокой концентрацией эффективных путей и формировать Парето-фронт, представляющий набор недоминируемых маршрутов с различным уровнем компромиссов между критериями эффективности.

Для проведения вычислительного эксперимента была выполнена программная реализация многокритериального алгоритма дождевых червей на языке *Python*. На основе входных данных сформированы маршруты, выполнена их оценка по трем критериям и осуществлен многокритериальный выбор лучшего. На рисунке 2(а) и рисунке 2(б) показаны три матрицы (расстояний, времени и сложности), лучшие по каждому критерию маршруты и маршрут, наилучший по всем критериям. На рисунке 3 показана визуализация маршрута, который является Парето-оптимальным по совокупности показателей.

Входные данные задаются матрицами L , T и D , элементы которых формируются псевдослучайным образом в заданных диапазонах. Это позволяет моделировать разные условия транспортной сети при сохранении общей структуры задачи. Каждое решение представляет собой перестановку узлов между фиксированными точками A и O , что обеспечивает однократное прохождение всех промежуточных узлов и корректное сравнение альтернативных маршрутов. Оценка качества маршрутов выполняется путем вычисления суммарного расстояния, времени и сложности, после которой формируется множество Парето-оптимальных решений.

Результаты применения *EWA* к многокритериальной задаче маршрутизации показывают, что алгоритм устойчиво формирует множество качественных недоминируемых решений, отражающих баланс между протяженностью, временем и сложностью маршрута. Характерно наблюдение, что на начальных этапах поисковая активность алгоритма высока, что способствует генерации разнообразных маршрутов, а на поздних этапах усиливается локальный поиск, позволяющий улучшать структуру наиболее перспективных решений. Концентрация полученных маршрутов вблизи Парето-фронта подтверждает способность алгоритма эффективно исследовать сложное пространство поиска и находить компромиссные варианты.

Матрица расстояний (L):															
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
A	0	112	102	24	116	81	30	112	131	84	97	126	109	113	140
B	112	0	62	11	97	47	139	30	67	31	98	58	68	24	60
C	102	62	0	117	64	73	140	60	144	30	82	27	141	98	69
D	24	11	117	0	23	18	99	62	139	93	101	120	17	44	90
E	116	97	64	23	0	59	113	141	11	143	63	115	13	63	53
F	81	47	73	18	59	0	23	104	57	24	49	91	120	62	33
G	30	139	140	99	113	23	0	133	50	24	54	74	98	80	18
H	112	30	60	62	141	104	133	0	97	138	145	72	148	90	145
I	131	67	144	139	11	57	50	97	0	42	132	14	50	37	144
J	84	31	30	93	143	24	24	138	42	0	81	21	42	57	71
K	97	98	82	101	63	49	54	145	132	81	0	46	108	113	44
L	126	58	27	120	115	91	74	72	14	21	46	0	110	140	10
M	109	68	141	17	13	120	98	148	50	42	108	110	0	14	112
N	113	24	98	44	63	62	80	90	37	57	113	140	14	0	36
O	140	60	69	90	53	33	18	145	144	71	44	10	112	36	0

Матрица времени (T):															
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
A	0	13	83	19	94	46	81	55	67	100	107	117	56	100	8
B	13	0	98	105	27	107	113	19	47	33	40	17	36	75	63
C	83	98	0	119	90	32	70	46	49	66	61	10	32	32	112
D	19	105	119	0	48	88	34	66	79	96	93	107	66	101	5
E	94	27	90	48	0	31	66	120	81	109	7	107	74	76	31
F	46	107	32	88	31	0	13	66	41	101	55	110	48	28	83
G	81	113	70	34	66	13	0	63	36	100	92	109	56	117	66
H	55	19	46	66	120	66	63	0	117	62	56	16	43	6	7
I	67	47	49	79	81	41	36	117	0	117	105	117	60	85	63
J	100	33	66	96	109	101	100	62	117	0	117	6	6	96	58
K	107	40	61	93	7	55	92	56	105	117	0	91	105	100	101
L	117	17	10	107	107	110	109	16	117	6	91	0	5	23	6
M	56	36	32	66	74	48	56	43	60	6	105	5	0	57	48
N	100	75	32	101	76	28	117	6	85	96	100	23	57	0	94
O	8	63	112	5	31	83	66	7	63	58	101	6	48	94	0

Рис. 2(а) – Результат работы программы

Матрица сложности (D):

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
A	0	6	23	4	23	11	24	27	17	6	24	5	20	2	6
B	6	0	22	11	16	16	1	9	28	27	6	16	29	3	20
C	23	22	0	28	27	4	19	26	3	19	20	7	20	9	1
D	4	11	28	0	8	7	18	8	1	11	28	25	25	18	23
E	23	16	27	8	0	30	10	3	7	28	16	26	16	25	20
F	11	16	4	7	30	0	28	17	2	1	16	30	12	5	5
G	24	1	19	18	10	28	0	27	23	9	9	3	19	16	16
H	27	9	26	8	3	17	27	0	3	20	24	22	24	1	24
I	17	28	3	1	7	2	23	3	0	20	11	17	8	4	6
J	6	27	19	11	28	1	9	20	20	0	8	20	30	3	16
K	24	6	20	28	16	16	9	24	11	8	0	30	25	3	25
L	5	16	7	25	26	30	3	22	17	20	30	0	29	18	14
M	20	29	20	25	16	12	19	24	8	30	25	29	0	18	2
N	2	3	9	18	25	5	16	1	4	3	3	18	18	0	22
O	6	20	1	23	20	5	16	24	6	16	25	14	2	22	0

Лучший по расстоянию: A-D-E-I-G-F-C-K-B-N-M-J-L-O | (591, 430, 192)
 Лучший по времени: A-D-E-K-B-I-G-F-N-C-H-J-M-L-O | (868, 395, 246)
 Лучший по сложности: A-E-D-I-M-F-C-N-K-B-H-G-L-J-O | (1159, 788, 149)
 Лучший по всем критериям: A-D-E-I-G-F-C-K-B-N-M-J-L-O | (591, 430, 192)

Рис. 2(б) – Результат работы программы

Лучший по всем критериям (L+T+D) — L=591, T=430, D=192

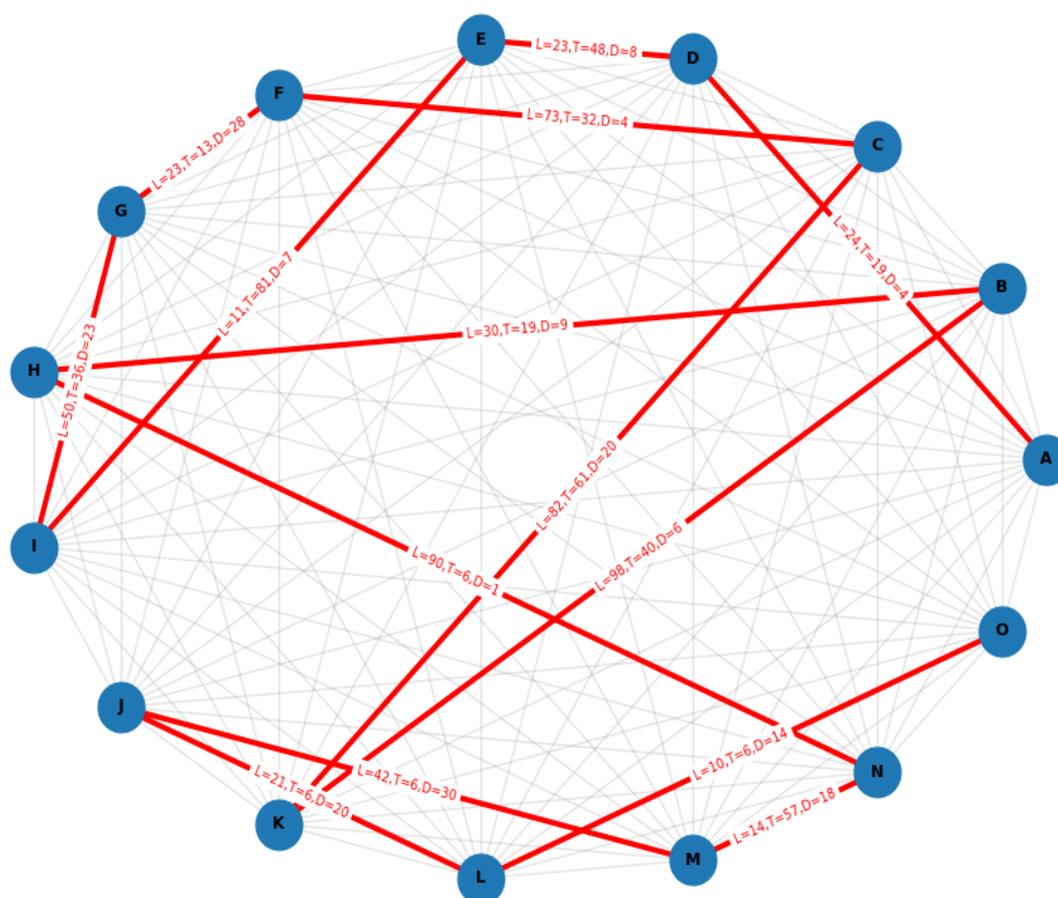


Рис. 3 – Визуализация наилучшего решения

Для количественной оценки эффективности предложенного биоинспирированного алгоритма дождевых червей был проведён сравнительный вычислительный эксперимент (Таблица 1). В качестве базовых методов сравнения использовались метаэвристические алгоритмы, наиболее часто применяемые для решения задачи коммивояжёра и задач маршрутизации в логистике возвратов, а именно алгоритмы имитации отжига, муравьиной колонии и роя частиц.

Результаты валидации разработанного метода

Таблица 1

Показатель	<i>EWA</i>	<i>SA</i>	<i>ACO</i>	<i>PSO</i>
Время выполнения алгоритма, мин.	4,5	3	5	4
Стоимость маршрута, усл. ед.	696	856	763	745

Совокупность полученных данных подтверждает, что алгоритм дождевых червей обладает значительными возможностями для применения в системах поддержки принятия решений, связанных с организацией возвратной логистики. Он способен адаптироваться к многокритериальным условиям, эффективно работать с перестановочными структурами и формировать устойчивые решения даже при высокой сложности задачи. Это делает *EWA* перспективным инструментом для анализа возвратных потоков в электронной коммерции и оптимизации траекторий движения товаров в рамках интеллектуальных транспортных систем.

2. Применение нечеткого случайного леса для классификации причин возврата товара в электронной коммерции

Одной из ключевых задач аналитики возвратов в электронной коммерции является корректная классификация причин возврата товаров. Результаты такой классификации используются при управлении качеством продукции, оптимизации логистических процессов и повышении удовлетворённости клиентов. В современной научной литературе [9-10] данная задача рассматривается в рамках задач классификации и интеллектуального анализа данных, для решения которых предложен широкий спектр методов.

Одним из перспективных инструментов для решения подобных задач является нечеткий случайный лес (*Fuzzy Random Forest, FRF*) [11], представляющий собой ансамбль нечетких деревьев решений. В отличие от одиночного нечеткого дерева, которое моделирует степень принадлежности объекта к определённым интервалам признаков, нечеткий случайный лес объединяет выводы множества таких деревьев, что существенно повышает точность, устойчивость и обобщающую способность модели. Применение *FRF* позволяет учитывать «размытый» характер данных о возвратах: фразы вида «качество скорее неудовлетворительное», «товар приблизительно соответствует описанию» или «скорость доставки была средняя» интерпретируются в терминах степеней принадлежности. Вместо того, чтобы жестко отнести объект к одному классу, модель анализирует вклад всех деревьев и всех листовых узлов.

Обобщенная математическая постановка задачи классификации выглядит следующим образом. Пусть имеется множество причин R и множество классов C , между которыми существует зависимость $s^*: R \rightarrow C$, известная на объектах выборки R^S . Алгоритм $alg: R \rightarrow C$, классифицирует любую причину $r \in R$.

Классические деревья решений предполагают строгое отнесение объекта к одному узлу и, соответственно, к одному классу. Однако в реальных данных о возвратах товаров такая жесткая схема часто оказывается неприемлемой. Причины возврата нередко выражены неоднозначно, формулировки клиентов могут быть интерпретированы сразу в нескольких контекстах, а часть признаков содержит шумы, пропуски или неточные значения. Более того, даже количественные показатели, такие как рейтинг качества, обладают субъективной природой, поскольку основаны на индивидуальном восприятии клиента. В результате традиционные модели теряют значительную долю информации, имеющую субъективный характер.

Нечеткие деревья решений позволяют смягчить указанные ограничения благодаря использованию лингвистических меток и функций принадлежности, определяющих степень соответствия признаков различным категориям [12]. Это делает возможным ситуацию, когда объект одновременно принадлежит нескольким ветвям дерева с разной интенсивностью, что обеспечивает более гибкую интерпретацию данных. Однако именно ансамблирование множества таких деревьев в структуре *FRF* делает классификацию гораздо более устойчивой, снижая влияние ошибок отдельных деревьев и расширяя охват конфигураций признаков.

Построение каждого дерева внутри *FRF* основано на использовании функций принадлежности и специальных нечетких критериев разделения, таких как *Fuzzy Information Gain* или *Fuzzy Gini*. Более продвинутые версии модели используют интуиционистские нечеткие множества (*IFS*) и критерии *Intuitionistic Fuzzy Information Gain*, учитывающие не только принадлежность объекта категории, но и степень непринадлежности и уровень неопределённости. Это делает деревья, а вместе с ними и весь ансамбль, менее чувствительными к вариативности данных.

При построении ансамблевых моделей, таких как нечеткий случайный лес, результаты классификации могут определяться с использованием различных схем голосования. На рисунке 4(а) и рисунке 4(б) представлены две такие схемы: во-первых, голосование на основе дерева, при котором итоговый класс определяется агрегированием весов, полученных от каждого дерева в целом; во-вторых, голосование на основе листьев, когда учитывается вклад веса каждого листа и дерева одновременно. Оба подхода позволяют учитывать степень принадлежности классу на разных уровнях структуры модели, что делает процесс классификации более гибким и информативным.

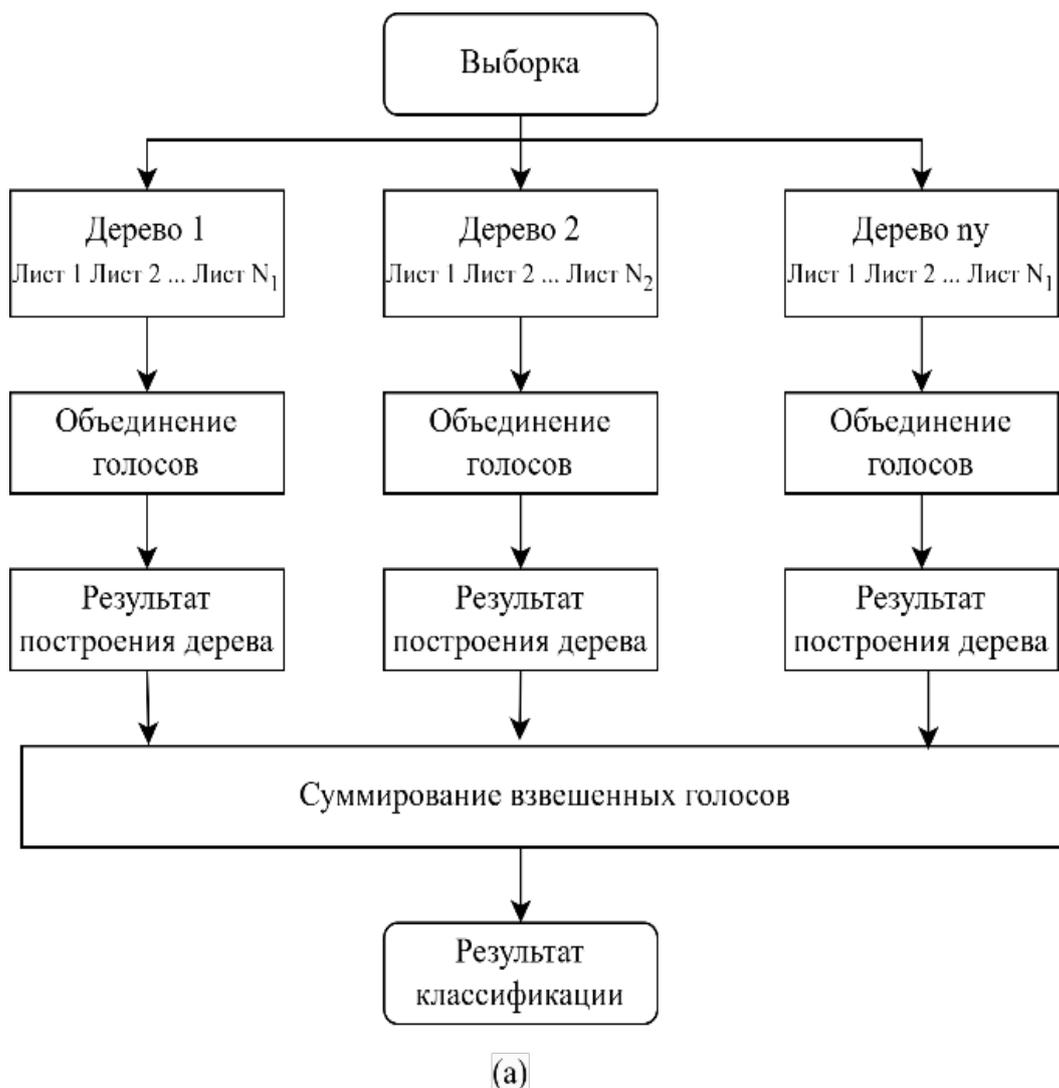
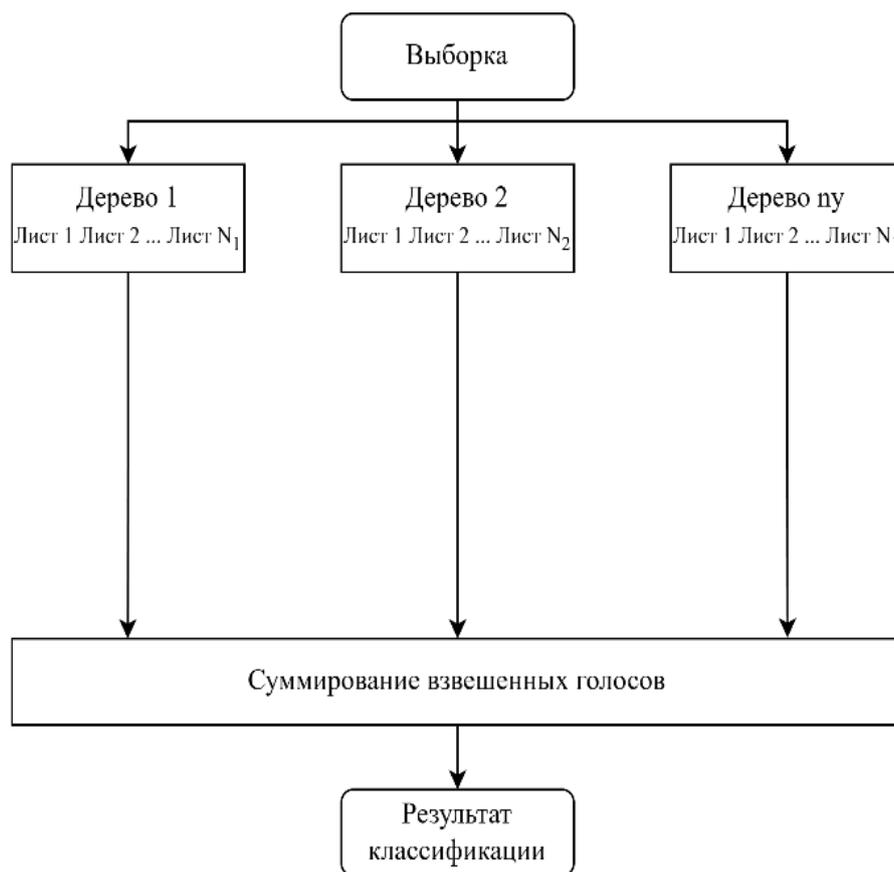


Рис. 4(а) – Схемы голосования на основе дерева (а) и листьев (б)



(б)

Рис. 4(б) – Схемы голосования на основе дерева (а) и листьев (б)

В контексте классификации причин возврата товаров нечеткий случайный лес оказывается эффективным, поскольку позволяет учитывать специфику данных, которые часто отличаются высокой степенью недоверности, субъективности и неполноты. Клиент может указать лишь приблизительное описание проблемы, неверно интерпретировать ситуацию или опустить важные детали. Нечеткие модели способны работать с такими размытыми формулировками благодаря механизму степеней принадлежности, что уменьшает влияние субъективных ошибок пользователей.

Дополнительная сложность заключается в том, что данные о возвратах включают как количественные, так и качественные характеристики. Числовые показатели, такие как цена, рейтинг товара или скорость доставки, сосуществуют с разнородными текстовыми, эмоциональными оценками. *FRF* позволяет объединять эти различные типы признаков в едином аналитическом пространстве, преобразуя качественные параметры в нечеткие множества и интегрируя их с количественными.

Существенным преимуществом *FRF* является его интерпретируемость. Несмотря на ансамблевую структуру, отдельные деревья сохраняют прозрачность правил, что помогает объяснить причины отнесения объекта к определённому классу и выявить наиболее важные факторы возврата. Это делает модель полезной не только как классификатор, но и как инструмент объяснимой аналитики.

Нечеткие модели обладают высокой устойчивостью к шуму, пропускам и противоречивости данных, что особенно важно в электронной коммерции, где информация заполняется пользователями нерегулярно и может содержать многочисленные разночтения. Благодаря мягкому распределению объектов между категориями *FRF* сохраняет точность и стабильность анализа даже при существенных дефектах исходных данных.

Интеграция нечеткой логики с методом случайного леса позволяет значительно повысить точность классификации при наличии неоднозначных значений, пропусков и сложных нелинейных зависимостей. Ансамблевый подход усиливает устойчивость модели

к ошибкам отдельных деревьев, а нечеткая логика обеспечивает корректную обработку промежуточных состояний признаков, которые традиционные алгоритмы интерпретируют недостаточно корректно. Это делает *FRF* эффективным инструментом для анализа возвратов, поскольку он способен учитывать многообразие факторов, выявлять скрытые зависимости и обеспечивать надежные результаты в условиях высокой вариативности данных.

Программная реализация предложенного метода была выполнена на языке *Python* с использованием с библиотеками *pandas*, *numpy*, *scikit-learn* и *fuzzydecisiontree*. Проверка ее работоспособности проводилась на выборке в 2000 записей, которые были разделены на 10 классов (результаты представлены в таблице 2).

Таблица 2

Сравнение случайного леса и нечеткого случайного леса

Метод	Точность	Полнота	Ошибка	F-метрика
Случайный лес	0,77	0,74	0,23	0,76
Нечеткий случайный лес	0,84	0,80	0,16	0,82

Включение *FRF* в систему классификации причин возвратов существенно повышает качество аналитики. Модель естественным образом учитывает субъективность клиентских оценок, эффективно работает с неполными и неточными данными и способствует выявлению скрытых факторов, трудно обнаруживаемых традиционными методами. Прозрачность логики принятия решений облегчает разработку мер по снижению числа возвратов.

В совокупности эти свойства делают нечеткий случайный лес перспективным инструментом для классификации причин возврата товара. Он обеспечивает высокую точность анализа, выявляет скрытые закономерности, снижает влияние субъективности клиентов и способствует сокращению числа необоснованных возвратов за счёт более глубокого понимания механизмов их возникновения.

3. Архитектура системы поддержки принятия решений для управления возвратами

Управление возвратами в электронной коммерции представляет собой сложный многоэтапный процесс, включающий логистические операции, анализ клиентского поведения, контроль качества товаров, управление ассортиментом и организацию сервисного обслуживания. В условиях роста объёмов онлайн-продаж и повышения требований клиентов эффективное управление возвратами становится стратегической задачей, напрямую влияющей на финансовую устойчивость и конкурентоспособность компании. Именно поэтому всё большее значение приобретает внедрение систем поддержки принятия решений (СППР), способных обеспечить комплексный анализ данных и формирование обоснованных управленческих решений.

В отличие от распространённых корпоративных аналитических решений и BI-платформ, которые, как правило, ориентированы на ретроспективный анализ статистических показателей, предлагаемая СППР ориентирована на интеллектуальную обработку данных и формирование рекомендаций в условиях многокритериальности и неопределённости. Система использует методы искусственного интеллекта для одновременного решения двух ключевых задач управления возвратами: оптимизации маршрутов возвратной логистики и классификации причин возвратов товаров. Это принципиально отличает предложенную СППР от существующих решений, в которых данные задачи, как правило, рассматриваются разрозненно либо решаются с применением детерминированных или слабоадаптивных методов.

СППР, интегрированная в процесс возвратной логистики, выполняет роль интеллектуального посредника между различными подсистемами электронной коммерции: логистикой, клиентским сервисом, управлением каталогом товаров и аналитическими модулями. Основная задача такой системы заключается в том, чтобы предоставить

менеджменту доступ к релевантной, структурированной и интерпретируемой информации, обеспечив тем самым возможность оперативного и обоснованного принятия решений. В отличие от традиционных инструментов, ориентированных на простую обработку статистических показателей, СППР использует методы искусственного интеллекта, позволяющие выявлять скрытые зависимости, прогнозировать тенденции и оптимизировать операции в условиях многокритериальности и неопределённости [13].

В предлагаемой архитектуре СППР для управления возвратами используется сочетание двух интеллектуальных модулей: модуля оптимизации маршрутов, основанного на биоинспирированном алгоритме *EWA*, и модуля классификации причин возвратов, использующего нечеткий случайный лес. Первый модуль отвечает за формирование рациональных траекторий движения возвратного товара, позволяя снижать логистические издержки, уменьшать время возвратных операций и поддерживать устойчивость транспортной сети в условиях изменяющихся внешних факторов. Второй модуль ориентирован на анализ информации о причинах возвратов, что даёт возможность выявлять основные источники неудовлетворённости клиентов, определять факторы риска и формировать рекомендации, направленные на повышение качества ассортимента и совершенствование клиентского сервиса.

Архитектура СППР создаётся на основе модульного принципа, что обеспечивает её масштабируемость, гибкость и возможность интеграции с существующей цифровой инфраструктурой электронной коммерции. Каждый модуль выполняет специализированные задачи, однако их совместная работа формирует единое аналитическое пространство, позволяющее комплексно анализировать возвратные процессы и принимать управленческие решения на основе объективных данных.

На рисунке 5 представлена архитектура СППР. Модуль оптимизации маршрутов выступает центральным инструментом возвратной логистики. Используя матрицы расстояний, времени и сложности, он последовательно генерирует альтернативные маршруты, оценивает их на основе многокритериальной функции и формирует множество недоминируемых решений. Такой подход делает систему устойчивой к изменениям внешней среды, например, к пробкам, изменениям стоимости транспортировки или неравномерному распределению возвратных потоков. Итоговая информация, включающая сбалансированные по критериям маршруты, передаётся в интеграционный модуль.

Модуль классификации причин возвратов анализирует данные о текстовых описаниях, характеристиках товаров, параметрах заказа и профиле клиента. Использование нечетких деревьев решений позволяет учитывать неопределённость и субъективность данных, что особенно важно для задач, где причины возвратов формулируются клиентами неявно и неполно. На основе классификационных моделей система выявляет ключевые факторы возникновения возвратов и обеспечивает аналитическую поддержку при корректировке товарной политики, улучшении описаний и оптимизации процессов обслуживания клиентов.

Модуль визуализации предоставляет результаты работы интеллектуальных модулей в наглядной и структурированной форме. Интерфейс отображает матрицы расстояний, времени и сложности, наилучшие маршруты по каждому из критериев и рациональный по всем критериям, а также их и их графическое представление, распределение причин возвратов, структуру классификационных деревьев, динамику логистических метрик. Такая визуализация облегчает принятие решений специалистами, не обладающими глубокими знаниями в области анализа данных и машинного обучения, и способствует повышению прозрачности логистических процессов.

База данных возвратов и логистических сведений является фундаментом архитектуры. Она аккумулирует данные о товарах, заказах, клиентах, транспортной инфраструктуре и складах, а также результаты обработки возвратов. Хранилище обеспечивает единообразие данных и поддерживает взаимодействие с внешними и внутренними системами, включая *WMS*, *ERP*, торговые площадки и сервисы транспортных операторов. Это позволяет СППР функционировать в режиме регулярного обновления данных и поддерживать актуальность аналитических моделей.

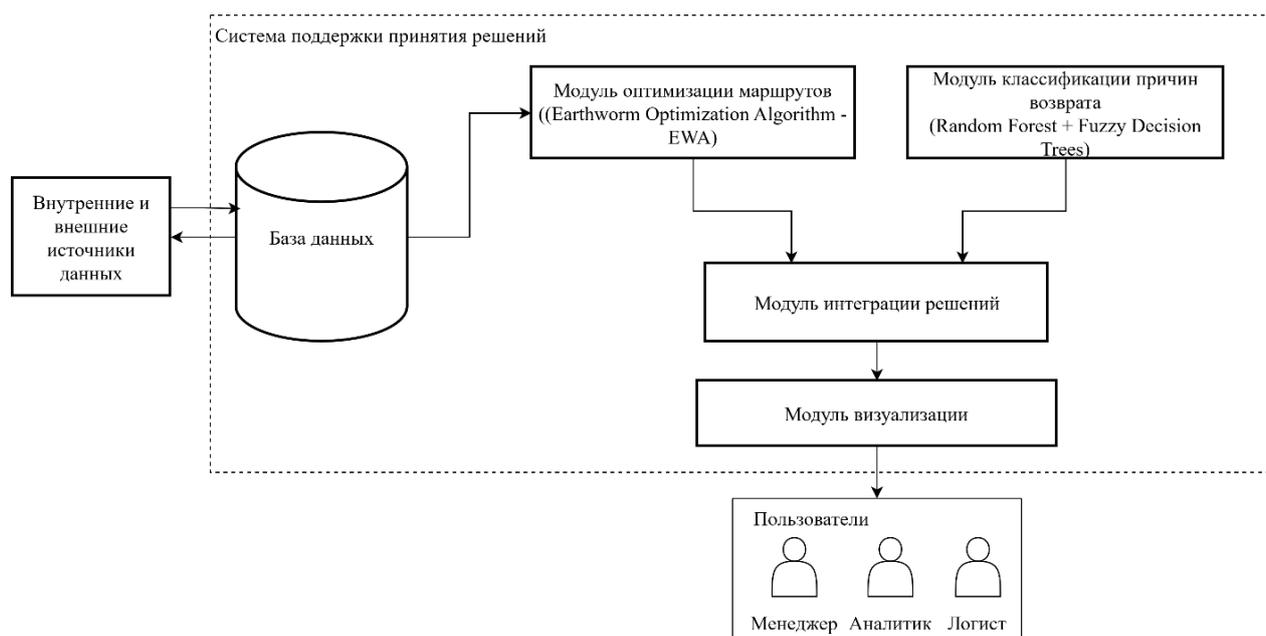


Рис. 5 – Архитектура СППР

Алгоритм взаимодействия модулей системы поддержки принятия решений основан на параллельной работе двух независимых аналитических цепочек. После поступления данных в хранилище выполняются этапы очистки и нормализации, формирующие единый массив структурированных и слабоструктурированных данных. Далее информация распределяется по двум направлениям анализа: первая часть данных, связанная с логистическими характеристиками транспортной сети, поступает в модуль оптимизации маршрутов, где биоинспирированный алгоритм дождевых червей осуществляет многокритериальную оптимизацию и формирует набор рациональных маршрутов возврата товара, вторая часть данных, содержащая текстовые описания, характеристики товаров и клиентские оценки, направляется в модуль классификации причин возвратов, в котором нечеткий случайный лес формирует интерпретируемую модель причин возврата и выявляют ключевые факторы, влияющие на их возникновение.

Результаты обоих модулей не объединяются в единое решение, поскольку они решают разные управленческие задачи. Модуль оптимизации предоставляет логистам лучшие маршруты возврата, а модуль классификации предлагает аналитические выводы о причинах возникновения возвратов и направлениях улучшения качества продукции или сервиса. Интеграционная подсистема отвечает лишь за согласованный доступ к результатам работы модулей, их одновременное отображение в едином интерфейсе и формирование комплексной картины возвратных потоков, не выполняя операции объединения данных или взаимного влияния результатов. В завершении анализа данные передаются в модуль визуализации, который отображает оптимальные маршруты, статистику причин возвратов и ключевые показатели эффективности.

Интеграция системы поддержки принятия решений с существующими логистическими платформами и *WMS* является важным элементом её внедрения. Система взаимодействует с внешними источниками данных через *API*-интерфейсы, механизмы обмена сообщениями или *ETL*-процедуры, что позволяет автоматически получать сведения о возвратах, перемещениях товаров, статусах заказов, транспортных операциях и клиентских отзывах. Такое взаимодействие обеспечивает постоянное обновление базы данных, возможность оперативного пересчёта маршрутов, регулярное обновление классификационных моделей и использование актуальной информации в процессе принятия решений. Благодаря модульной структуре интеграция может выполняться поэтапно, без необходимости изменения всей ИТ-архитектуры предприятия. В результате эффективной интеграции и обеспечения актуальности данных все технические возможности системы трансформируются в конкретные экономические выгоды.

Экономическая эффективность внедрения СППР для управления возвратами проявляется через комплексный эффект, включающий снижение прямых издержек, уменьшение

логистических потерь, повышение качества клиентского сервиса и сокращение числа необоснованных возвратов. Комплексность эффекта объясняется системной природой изменений: СППР влияет как на оперативные процессы, так и на стратегические решения.

Прежде всего, применение модуля оптимизации маршрутов позволяет снизить транспортные расходы за счёт сокращения расстояния перевозки, уменьшения времени в пути и выбора маршрутов с минимальной логистической сложностью. В условиях высокой стоимости «последней мили» даже небольшое улучшение маршрута может дать значительный экономический эффект, особенно в крупных компаниях, обрабатывающих тысячи возвратных заказов ежедневно.

Вторым значимым компонентом экономического эффекта является снижение доли необоснованных или избыточных возвратов. Модуль классификации причин возврата выявляет скрытые закономерности в клиентском поведении, помогает обнаружить «проблемные» группы товаров, некорректные описания и ошибки сервиса. Это позволяет компании предпринять меры для улучшения качества контента, оптимизации упаковки, повышения точности характеристик, внедрения дополнительных фильтров при оформлении заказа или изменения условий взаимодействия с поставщиками. Снижение числа возвратов даже на 5-10% приводит к значительной экономии, поскольку возврат включает не только затраты на логистику, но и потери от обесценивания товара.

Дополнительный эффект создаётся за счёт ускорения принятия решений. Руководители получают доступ к визуализированным данным и рекомендациям в реальном времени, что позволяет оперативно корректировать логистические операции, уменьшать задержки и повышать оборачиваемость складских запасов. Повышается эффективность работы сотрудников, сокращается время на подготовку аналитических отчётов и ручной анализ данных.

Наконец, важным источником экономической выгоды является повышение уровня удовлетворенности клиентов. Классификация причин возвратов и улучшение качества коммуникаций приводит к росту лояльности потребителей, снижению риска ухода к конкурентам и повышению повторных покупок, что является одним из ключевых источников роста доходов в электронной коммерции.

Таким образом, экономическая оценка внедрения СППР демонстрирует выраженный положительный эффект за счет комплексного влияния системы на логистические, операционные и клиентские показатели. Реализация такой системы позволяет компаниям электронной коммерции существенно повысить эффективность управления возвратами и увеличить конкурентоспособность на насыщенном рынке.

Заключение

Проведенное исследование показало, что сочетание биоинспирированных методов оптимизации и нечетких моделей классификации позволяет сформировать эффективную и устойчивую систему поддержки принятия решений для управления возвратами в электронной коммерции. Алгоритм дождевых червей показывает высокую адаптивность к условиям многокритериальной маршрутизации и способность формировать качественные решения даже в условиях огромного пространства поиска и нестабильной логистической среды. Это делает его перспективным инструментом для оптимизации возвратных потоков, где требуется учитывать расстояние, время и логистическую сложность одновременно.

Использование нечеткого случайного леса обеспечивает более точный и интерпретируемый анализ причин возвратов, позволяя работать с субъективной, лингвистически описанной и неполной информацией. Такие модели отражают реальную природу данных электронной коммерции, где информация нередко бывает размыта, неполна и зависит от индивидуального восприятия клиента. Интеграция нечетких методов с классическими ансамблевыми алгоритмами усиливает их устойчивость и точность, создавая аналитическую основу для сокращения числа возвратов и улучшения качества обслуживания.

Разработанная архитектура СППР демонстрирует способность объединять интеллектуальные модули в единую информационную систему, обеспечивающую комплексный анализ возвратов. Модульный принцип построения, поддержка интеграции с *WMS*, *ERP* и торговыми платформами, а также наличие развитой подсистемы визуализации обеспечивают высокую применимость системы в реальных условиях электронной

коммерции. Параллельная обработка логистических и аналитических данных позволяет получать актуальные рекомендации в реальном времени и принимать обоснованные управленческие решения.

Экономическая оценка показала, что внедрение СППР способствует снижению логистических расходов, уменьшению доли необоснованных возвратов, сокращению операционных задержек и повышению удовлетворённости клиентов. В совокупности эти факторы формируют значимый положительный эффект и повышают устойчивость и конкурентоспособность компании на рынке.

Таким образом, предложенная система поддержки принятия решений представляет собой комплексный инструмент для управления возвратами, объединяющий современные методы искусственного интеллекта и логистического анализа. Применение алгоритма дождевых червей и нечеткого случайного леса открывает новые возможности для повышения эффективности возвратной логистики, улучшения клиентского опыта и оптимизации операционной деятельности в электронной коммерции.

Исследование выполнено в рамках государственного задания Минобрнауки России (проект № FSWF-2023-0012).

Список использованной литературы

1. Эльканова Е. А. Развитие электронной коммерции как фактор использования современных подходов в логистических маршрутах // *Вестник евразийской науки*. – 2025. – Т. 17, № s4. [Электронный ресурс]. – URL: <https://esj.today/PDF/33FAVN425.pdf>.
2. S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, "Optimization by Simulated Annealing," *Science*, vol. 220, no. 4598, pp. 671–680, 1983.
3. M. Dorigo, V. Maniezzo, and A. Colomi, "Distributed Optimization by Ant Colonies," in *Proc. Eur. Conf. Artif. Life (ECAL)*, pp. 134–142, 1991.
4. J. Kennedy and R. Eberhart, "Particle Swarm Optimization," in *Proc. IEEE Int. Conf. Neural Netw.*, vol. 4, pp. 1942–1948, 1995.
5. Кошуняева Н. В., Тутыгин А. Г. Сравнительный анализ эффективности использования метаэвристических методов моделирования для решения задачи коммивояжера // *Моделирование и анализ данных*. – 2025. – № 15(3). – С. 76–93.
6. A. Thakur, D. Giri, S. Panda, and R. Usharani, "Optimizing Electric Vehicle Routing: A Statistical Analysis of ACO, GA, and SA Algorithms," *Int. J. Eng. Res. Technol.*, vol. 13, no. 4, 2024.
7. G.-G. Wang and S. Deb, "Earthworm optimisation algorithm: a bio-inspired metaheuristic algorithm for global optimisation problems," *Int. J. Bio-Inspired Comput.*, vol. 12, no. 1, pp. 1–22, 2018.
8. Бульгина О. В. Конструирование экономико-математических моделей многокритериальной оптимизации на основе гибридных метаэвристик // *Прикладная информатика*. – 2025. – Т. 20, № 3. – С. 66–84.
9. A. Mishra and P. Dutta, "Return management in e-commerce firms: A machine learning approach to predict product returns and examine variables influencing returns," *J. Clean. Prod.*, vol. 477, p. 143802, 2024.
10. M. Farber, S. Novgorodov, and I. Guy, "Learning reasons for product returns on e-commerce," in *Proc. 7th Workshop e-Commer. NLP*, pp. 1–7, 2024.
11. Y. Ren, X. Zhu, and K. Bai, "A New Random Forest Ensemble of Intuitionistic Fuzzy Decision Trees," *IEEE Trans. Fuzzy Syst.*, vol. 31, no. 5, pp. 1729–1741, 2022.
12. Кириллова Е. А., Пучков А. Ю., Минин В. С., Ярцев Д. Д. Нейро-нечеткая модель ресурсного обеспечения инновационной деятельности промышленного предприятия // *Прикладная информатика*. – 2024. – Т. 19, № 5. – С. 126–142.
13. Бульгина О. В., Ярцев Д. Д., Прокимнов Н. Н., Вережкина Е. К. Направления гибридизации алгоритмов роевого интеллекта и нечеткой логики для решения оптимизационных задач в социально-экономических системах // *Прикладная информатика*. – 2024. – Т. 19, № 5. – С. 45–67.

УДК 004.89

ПОСТРОЕНИЕ КАРТЫ РАСПРЕДЕЛЕНИЯ АНОМАЛИЙ ИСПОЛНЕНИЯ ЛОГИСТИЧЕСКИХ ПРОЕКТОВ В УСЛОВИЯХ НЕОПРЕДЕЛЁННОСТИ

Беляков Станислав Леонидович, д.т.н., профессор, Южный федеральный университет (ЮФУ), Таганрог, Россия, E-mail: sbelyakov@sfnedu.ru

Израилов Лев Алексеевич, аспирант, Южный федеральный университет (ЮФУ), Таганрог, Россия, E-mail: izrailev@sfnedu.ru

АННОТАЦИЯ

Для успешной реализации логистической операции необходимо прогнозировать возможность возникновения непредвиденных ситуаций. Они способны вызывать нежелательные издержки. Требуется принятие решений, способствующих преодолению ситуаций. Однако такие решения нередко приходится принимать в условиях неполноты и неопределённости доступной информации. Изменчивость окружающей среды требует постоянной актуализации информации о факторах, влияющих на реализацию логистических операций. Получить полное представление обо всех этих факторах практически невозможно, поэтому при принятии решений важную роль играют опыт и знания. Впрочем, применимость знаний о решении отдельно взятой ситуации ограничивается факторами, которые были наблюдаемы в момент реализации. С целью преодоления данного недостатка в статье предлагается разработка модели переноса полезного знания из прецедентов в новую ситуацию на примере задачи определения зон влияния аномалий логистического проекта. Для реализации модели используется метод рассуждений на основе прецедентов (Case-Based Reasoning). Он позволяет решить новую задачу, применяя или адаптируя ранее используемое решение. Логистические проекты описываются геоинформационными моделями.

Ключевые слова: интеллектуальные геоинформационные системы, геоинформационные системы, прецедентный анализ, принятие решений в условиях неопределённости.

BUILDING A DISTRIBUTION MAP OF ANOMALIES IN THE EXECUTION OF LOGISTICS PROJECTS UNDER CONDITIONS OF UNCERTAINTY

Stanislav L. Belyakov, Doctor of Technical Sciences, Professor, Southern Federal University (SFU), Taganrog, Russia, E-mail: sbelyakov@sfnedu.ru

Lev A. Izrailev, PhD student, Southern Federal University (SFU), Taganrog, Russia, E-mail: izrailev@sfnedu.ru

ANNOTATION

For the successful implementation of a logistics operation, it is necessary to predict the possibility of unforeseen situations. They can cause undesirable costs. It requires making decisions that help to overcome situations. However, such decisions often have to be made in conditions of incompleteness and uncertainty of the available information. The variability of the environment requires constant updating of information about the factors affecting the implementation of logistics operations. It is almost impossible to get a complete picture of all these factors, so experience and knowledge play an important role in making decisions. However, the applicability of knowledge about solving a particular situation is limited by the factors that were observed at the time of implementation. In order to overcome this disadvantage, the article proposes the development of a model for transferring useful knowledge from precedents to a new situation using the example of the problem of determining the zones of influence of anomalies in a logistics project. The use-Case-Based Reasoning method is used to implement the model. It allows you to solve a new problem by applying or adapting a previously used solution. Logistics projects are described by geoinformation models

Keywords: intelligent geoinformation systems, geoinformation systems, precedent analysis, decision-making in conditions of uncertainty.

Введение

Состояние неопределённости остается одной из ключевых проблем принятия решений в логистическом проекте. В транспортных системах логистическим проектом называют совокупность процессов, связанных с планированием и оптимизацией перевозок грузов, проектированием цепей поставок, проектированием и оптимизацией работы склада и т. д. [26]. Состояние неопределенности представляют собой ситуации, в которых отсутствует полная информация о факторах, влияющих на результат выполнения логистических операций, в результате чего возникает опасность возникновения ущерба от неверно принятых решений.

Изменчивость окружающей среды становится важной проблемой в области управления логистикой. Управление логистикой определяется качеством принимаемых решений в таких условиях, когда доступная информация представляет собой ограниченный набор известных факторов, влияющих на реализацию проекта [5]. Получить полное представление обо всех этих факторах практически невозможно, поэтому при принятии решений важную роль играют знания и опыт, полученный при реализации предыдущих проектов. Однако применимость опыта решения отдельно взятой ситуации ограничивается факторами, которые были наблюдаемы в момент реализации. Поэтому эффективнее стремится к обобщению множества однотипных случаев для возможности определения всех возможных состояний, при которых применимо то или иное решение. Иными словами, следует определить допустимые преобразования ситуации, которые не изменяют ее суть.

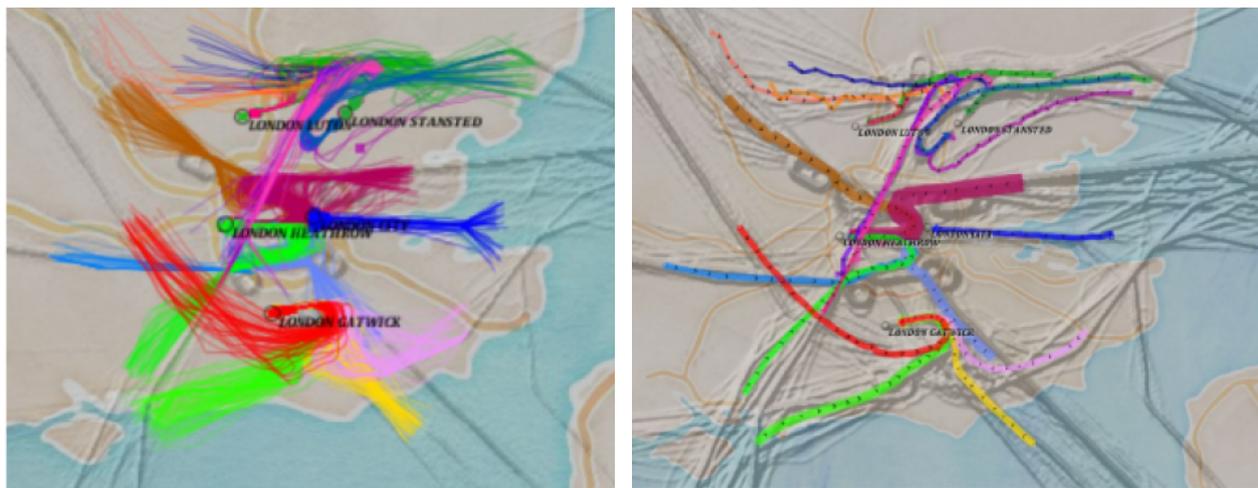


Рис. 1 – Обобщение траекторий движущихся объектов [20]

Рассмотрим следующий пример. На рисунке 1 (а) представлено множество траекторий движения летательных аппаратов в течении дня. На рисунке 1 (б) данные траектории были обобщены с помощью инструментов кластеризации. Представление множества отдельных траекторий в виде области допустимых траекторий полета (допустимых преобразований), значительно упрощает восприятие и позволяет выделить основные направления движения. В случае отсутствия информации о необходимой траектории движения маршрут движения может быть выбран в пределах области допустимых преобразований.

Накопленный опыт реализации проектов позволяет оценивать риски, связанные с возникновением непредвиденных ситуации в новом проекте по аналогии с уже известными случаями. Множество таких ситуаций в данной работе будут рассматриваться как аномалии логистического проекта.

Таким образом, в статье рассматривается возможность принятия решений в области логистического проекта в условиях неопределенности на основе его картографического представления. Основной целью является разработка модели переноса полезного знания из прецедентов в новую ситуацию на примере задачи определения зон влияния аномалий логистического проекта. Использование данной модели позволит определять зоны проявления аномалий при отсутствии информации о факторах и причинах их возникновения.

1. Обзор известных решений

Проблема принятия решений в условиях неопределённости в логистическом проекте исследуется довольно давно. Одним из направлений исследований является теория управления рисками. В рамках данной теории определяются основные решения и последствия их принятия в условиях неопределенности [3]. Они могут быть определены в том числе путем обобщения статистических данных [12]. Однако из-за непредсказуемости некоторых факторов, влияющих на последствия решений, такие решения составляют риск, который считается нежелательным и требует принятия превентивных мер, что негативно сказывается на эффективности проекта.

Говоря о рисках, отдельно стоит выделить направление аварийной логистики [7, 16]. Ее основная цель – максимально сократить время и свести к минимуму потери в результате аварийных ситуаций за счет эффективного распределения логистических процессов. Часто такие ситуации обладают неопределенностью данных, вследствие чего принятия решений в значительной степени выполняются экспертным методом и зависят от накопленного опыта решений похожих ситуаций [14]. В то же время субъективность эксперта способствует принятию необоснованных решений.

С целью преодоления субъективности разрабатываются информационные системы, использующие методы машинного обучения для прогнозирования и поддержки принятия решений [9, 19]. Подходы к машинному обучению выходят за рамки традиционных ограничений благодаря возможностям распознавания образов, которые обнаруживают сложные взаимосвязи в многомерных данных, постоянно адаптируясь к меняющимся условиям без ручного вмешательства эксперта [11].

В контексте логистики стоит упомянуть муравьиные алгоритмы [15]. Муравьиные алгоритмы моделируют процесс принятия решения на основе коллективного поведения. Каждый «муравей» в алгоритме представляет собой отдельное решение, которое постепенно улучшается в процессе поиска. Это позволяет исследовать множество возможных вариантов и находить нереализованные возможности для оптимизации. Кроме того, при наличии новых данных алгоритм способен адаптироваться к изменениям в условиях. Проведённые исследования [17, 18] демонстрируют эффективность алгоритма. Между тем, неустойчивость качества решения при изменении параметров следов «феромонов» и ограниченности эвристической информации составляет существенный недостаток для ситуаций неопределенности.

Другим направлением является использование имитационных моделей [4]. Имитационные модели иногда рассматриваются как «цифровые двойники» логистической системы. Такие модели позволяют моделировать систему максимально приближенную к реальности и анализировать реализацию проекта в разных условиях. Однако применение таких моделей в условиях недостатка и неопределённости информации затруднительно. Из-за невозможности учесть некоторые факторы, снижается надежность результатов. Также возникает проблема актуализации модели вследствие изменения параметров реального объекта.

В условиях усложнения структуры логистических проектов, возникает интерес к созданию больших языковых моделей (LLM, Large Language Models) для использования в задачах управления. Такие модели могут анализировать статистические данные, а также динамичные внешние факторы. Например, используя LLM, менеджеры логистических проектов могут получить рекомендации по оптимизации маршрутов доставки или распределению ресурсов [13]. Впрочем, нерешенными остаются проблемы переобучения и «галлюцинирования» таких моделей. Степень надежности ответов находится под большим вопросом.

В работе [22] отмечаются следующие недостатки использования LLM:

1. Неоднозначность пользовательских запросов. Пользователь рассуждает на интуитивном уровне, из-за чего часто опускает детали контекстуальные детали. Например, запрос «Покажи мне зоны затопления» без конкретных данных об осадках, топографии или временных рамок способен вызывать путаницу в ответах.
2. Поверхностные знания предметной области. Нерешенной остается проблема актуализации языковой модели. Запросы, требующие глубокого осмысления и новых знаний предметной области, могут привести к неполным или неверным результатам.

Таким образом, анализ литературы позволил сформулировать следующие недостатки существующих решений:

- Некоторые исследования чрезмерно фокусируются на машинном автоматизированном процессе принятия решений, игнорируя потенциал гибких суждений и опыта людей, принимающих решения в сложных ситуациях (в том числе в сценариях аварийной логистики).
- Существующие системы сосредоточены на стратегическом управлении и планировании. Им не хватает способности адаптироваться к изменениям в предметной области. В условиях изменчивых сценариев логистики и при недостатке информации, система не может своевременно предоставлять предложения для принятия решений.
- При проектировании систем поддержки принятия решений не всегда уделяется внимание представлению информации в интерфейсе интуитивно понятным образом, что затрудняет быстрое получение ключевой информации пользователем и влияет на эффективность принятия решений.
- Чтобы иметь возможность определить необходимый порядок действий, требуется создание сложных моделей, которые учитывают все возможные варианты развития ситуаций. Для их создания требуется сбор и накопление больших объемов данных, которые со временем устаревают из-за изменений в предметной области.

Преодоление данных недостатков возможно с помощью создания самообучающихся систем на основе опыта. Одним из методов реализации таких систем является прецедентный анализ.

Прецедентный анализ (CBR-анализ) используется для решения задач, используя ранее полученные прецеденты. В отличие от традиционных методов, которые требуют строгих правил и моделей, прецедентный анализ предлагает гибкость и адаптивность, а также возможность накапливать опыт принятия решений за счет применения CBR-цикла. Благодаря этому системы рассуждений на основе прецедентов нашли свое применение в задачах принятия решений для трудно формализуемых объектов управления, а также в сложных и динамичных предметных областях [1, 2]. Например, в работе [3] предлагается разработка системы поддержки принятия решений на основе рассуждения по прецедентам по оценке безопасности участка транспортной системы города. Однако данная система рассматривает пространственные характеристики, что создает проблему учета пространственного контекста.

Сочетание пространственной визуализации и интеллектуального метода анализа данных рассматривается в рамках создания методов геовизуальной аналитики и геоинформационных систем (ГИС). Такие системы отличаются высокой степенью интерактивности и множеством типов визуального представления пространственных данных, что можно считать важным преимуществом для принятия решений в условиях неопределенности. В работе [8] отмечается потенциал использования ГИС в исследованиях логистических проектов. Прежде всего, он играет важную роль в сборе данных, которые могут быть использованы в ходе текущего анализа, а также в последующие годы при сравнении с другими проектами.

Возможность «увидеть ситуацию», а не только оценить ее качественные и количественные характеристики, позволяет определить их сходства с учетом топологических особенностей [10]. Например, при планировании нового логистического проекта можно использовать геовизуальные методы для отображения на карте ранее реализованных проектов и принятых решений в новых условиях [6]. В свете этого интерес вызывают работы, посвященные применению рассуждений на основе географических знаний [21]. При этом, в работе отмечается, что доступные сегодня геоданные страдают неполнотой данных, что еще раз подчеркивают актуальность разработки моделей рассуждений в условиях неопределённости.

2. Форма представления знаний о аномалиях в логистическом проекте

Область реализации логистического проекта (ЛП) представляет собой пространство, в котором протекают процессы, связанные с выполнением основных его функций. Область ЛП условно можно задать тремя типами объектов: центры ЛП, маршруты ЛП и прецеденты ЛП. Центры ЛП – это физические или виртуальные локализации, которые являются узловыми точками в системе логистики. Маршруты ЛП представляют собой заранее определенные пути, по которым осуществляются перевозки от одного центра ЛП к другому.

Определим понятие аномалия, как возникновение в случайный момент времени непредвиденной ситуации, когда ожидания от совершения одного из процессов не выполняются. Например, процесс движения из точки А в В оказывается невозможным или длительность его выполнения значительно выше прогнозируемого. Тем не менее, не всегда аномалия в ЛП может характеризоваться аварийной ситуацией. Непредвиденные изменения условий могут не создавать угрозу безопасности, однако могут оказать негативное влияние на проект [25]. Например, увеличить временные издержки.

Возникновение аномалии, как и любой иной ситуации, является следствием совокупности факторов. Факторы привязаны к месту проявления (пространству) и могут быть связаны с природными, экономическими, социальными и технологическими условиями.

Знание о аномалиях представляет собой набор отношений и взаимосвязей между факторами окружающей среды, топологией местности и иных внешних условий. Представление аномалий в виде картографического объекта в отличие от простого словесного описания, позволяет отобразить в интуитивно понятной форме территории возникновения непредвиденных ситуаций и наделять соответствующими характеристиками прочие объекты в зависимости от того, как они соотносятся в пространстве.

Непрерывная область проявления аномалии составляет зону аномалий. Ситуации проявления аномалий представляют собой прецеденты. В качестве прецедентов рассматриваются конкретные проблемные ситуации, возникающие в процессе реализации логистических задач. Это могут быть примеры успешного решения логистической проблемы или описания неудачных случаев. Заложенный в прецеденты принцип «параметры ситуации – действие – обратная связь» позволяет в будущем заранее прогнозировать, к каким последствиям в похожих условиях ситуации, приведут те или иные принятые решения.

Модель прецедента представляется следующим образом:

$$CASE = (x_1, x_2, \dots, x_n, R)$$

где x_1, \dots, x_n – параметры ситуации, описывающей данный прецедент ($x_1 \in X_1, x_2 \in X_2, \dots, x_n \in X_n$), R – решение, n – количество параметров прецедента, а X_1, \dots, X_n – области допустимых значений параметров прецедента.

Параметры ситуации позволяют определить свойства текущей ситуации, чтобы сравнить его с другими прецедентами. В случае нахождения близкого прецедента, решение может быть повторно применено, либо без изменений, либо с применением процедуры адаптации. Новый решенный прецедент становится частью базы прецедентов. Описанный выше процесс составляет СВР-цикл. В результате его выполнения система реализует принцип самообучения, накапливая опыт в виде базы прецедентов.

В пространстве прецедент может быть представлен как область (линейный, полигональный), либо как точечный объект. Сравнение прецедентов может быть выполнено с помощью метрик близости. Выбор метрики близости зависит от параметров прецедента и предметной области.

Согласно гипотезе компактности, схожие прецеденты чаще лежат в одном классе, чем в разных, а, следовательно, и их решения применимы для всего класса подобных ситуаций. Поэтому при сравнении прецедентов следует учитывать не только фактические параметры текущей ситуации, но и любые другие неучтенные факторы, которые могут оказаться важными. В частности, следует рассматривать пространственный контекст. С его помощью становится возможным отделить одну группу прецедентов от другой.

Для сравнения пространственных ситуаций разумно применить геоинформационные системы [24]. Они могут быть применены в том числе и в условиях неопределенности. Например, в ситуациях аварийного реагирования, когда поступающая информация ограничена лишь пространственными характеристиками, использование прецедентного

анализа совместно с ГИС может значительно повысить эффективность и обоснованность принимаемых решений [23].

ГИС обладают необходимым инструментарием для накопления и анализа прецедентов в пространстве, а также способны визуализировать допустимые преобразования свойств ситуации. При поиске решения они позволяют учесть не только топологические особенности первоначальной зоны, но и «смысловую близость». Смысловая близость прецедентов может быть определена через пространственное расположение и набор отношений с другими объектами. Близкие ситуации в пространстве обладают общим контекстом. При этом расположение необязательно должно быть идентичным. Как было сказано ранее, допустимые преобразования ситуации позволяют определить границы, в пределах которых прецеденты сохраняют ее суть.

3. Построение модели пространственного анализа аномалий

Рассмотрим поэтапно процесс переноса полезного знания из реализованных проектов в новую ситуацию на примере задачи определения зон влияния аномалий ЛП (Рис. 2).

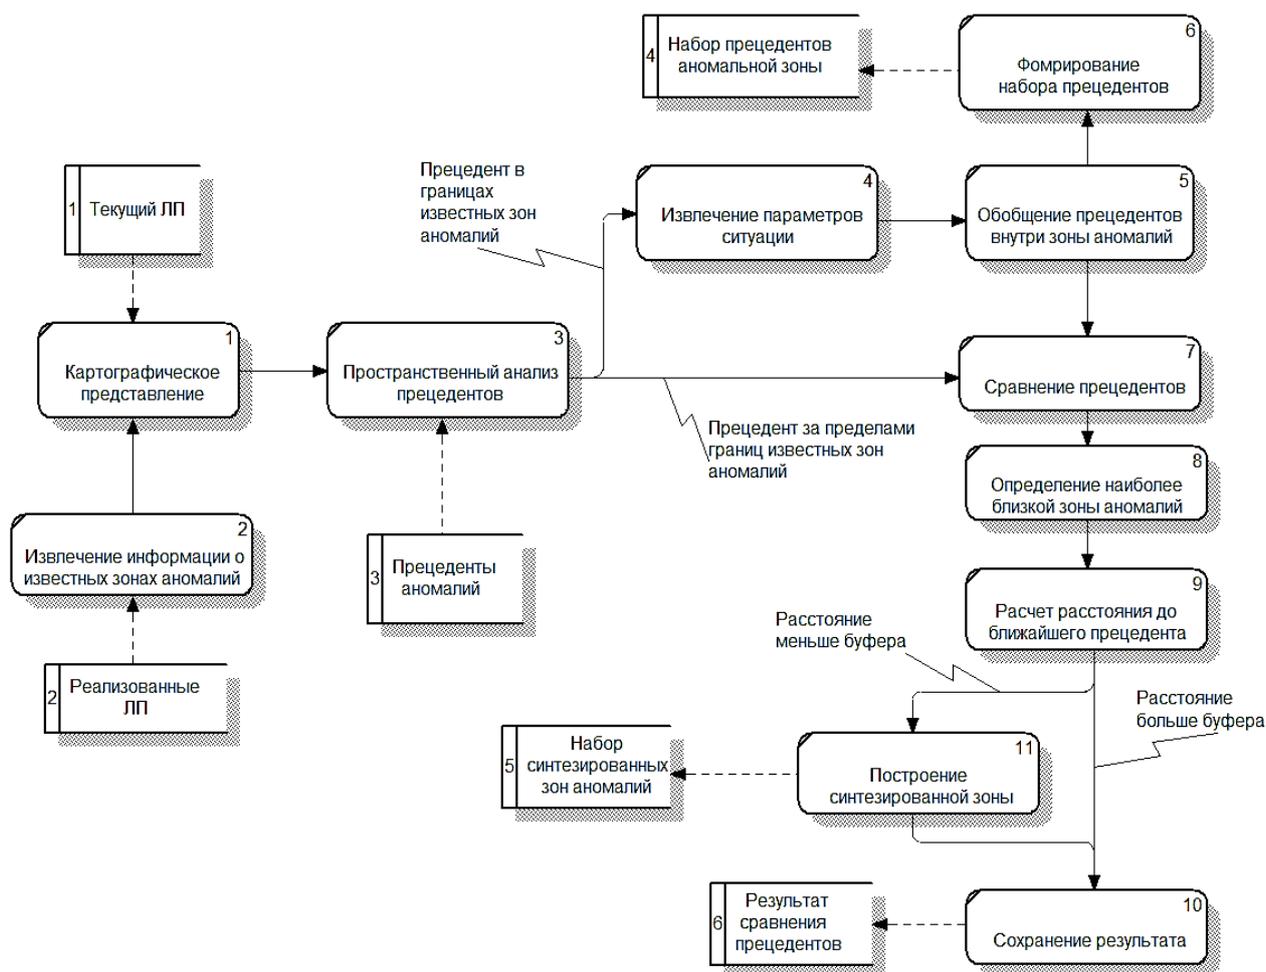


Рис. 2 – Модель рассуждений

Первым этапом является извлечение информации о известных зонах аномалий. Сведения о них могут быть получены из ранее реализованных ЛП в той же области.

Второй этап – картографическое представление ЛП. Должна быть определена область выполнения и пространственное расположение элементов ЛП, а также информация о известных зонах аномалий.

Третий этап – пространственный анализ прецедентов. Необходимо определить тип пространственных отношений между прецедентами и известными зонами аномалий. Например, находится прецедент в границах или за ее пределами известной аномальной зоны.

В случае если прецедент находится «внутри» аномальной зоны, то выполняется извлечение и последующее обобщение прецедентов. Все найденные прецеденты в одной зоне принадлежат к соответствующему классу аномалий и формируют набор прецедентов аномальной зоны.

На четвертом этапе запускается CBR-цикл, в ходе которого прецеденты, которые находятся за пределами зон аномалий сравниваются с набором прецедентов зоны аномалий. Чтобы оценить принадлежность ситуации к зоне аномалий определим все прецеденты, которые принадлежат области реализованного ЛП и известной зоне аномалий. Например, в зоне аномалий один прецедент произошел с параметром «день», другой «ночь». Значит при поиске прецедентов следует рассматривать прецеденты, которые произошли ночью и днем. В то же время, учитывая фактор возможной ковариации параметров, если один прецедент произошел «ночь, дождь», а другой «день, ясно», то не следует рассматривать близким сочетание параметров «день, дождь», так как соотношение двух величин могут быть линейно зависимыми.

Если в границах зоны аномалий существует близкий прецедент, то его соответствующий класс назначается для прецедента. В случае если требуется отделить прецеденты с низкой степенью соответствия, при расчетах может быть использовано пороговое значение, ниже которого прецеденты не считаются близкими.

Пятый этап – расчет расстояния до ближайшего прецедента. Если расстояние больше смыслового буфера, то прецедент рассматривается как единичный случай и зоны аномалий для него не строятся. Если расстояние меньше смыслового буфера, то считаем, что прецеденты формируют общую зону аномалий. Новая зона рассматривается как синтезированная и сохраняется основные характеристики исходной. Ее форма и топологические свойства строятся в зависимости от соответствующих свойств исходной зоны аномалии и от количества найденных прецедентов.

В результате создаются следующие наборы данных:

1. Прецеденты известной аномальной зоны;
2. Синтезированные зоны аномалий;
3. Результат сравнения прецедентов.

Допустим существует ЛП. В области проекта W^* расположено множество логистических центров S^* и множество маршрутов движения R между ними. Также предполагаем наличие зон аномалий A^* , на основании наличия данных о прецедентах C . Выбор маршрута движения зависит от количества пересекаемых этим маршрутом зон аномалий и степенью их опасности. Информация о зонах аномалий в проекте M^* первоначально неизвестна. Таким образом, ЛП можно описать моделью

$$M^* = (W^*, S^*, R^*, A^*)$$

Известны два реализованных логистических проекта M_a и M_b

$$M_a = (W_a, S_a, R_a, A_a), \quad \text{где } W_a \in W^*$$

$$M_b = (W_b, S_b, R_b, A_b), \quad \text{где } W_b \in W^*$$

Для проектов известны все зоны аномалий $A_{a,b}$ в пределах их границ. Чтобы определить зоны аномалий A^* воспользуемся анализом известных зон из реализованных проектов M_a и M_b и прецедентов аномалий C^* , свойства которых заданы множеством параметров P . Модель зоны аномалий для области текущего проекта

$$A^* = (P, C^*), \text{ где } C^* \in W^*$$

Определим P при которых аномалия возникает. Для этого проверим прецеденты на соответствие области проектов M_a и M_b

$$C_W^* = \{C_1^*, C_2^*, \dots, C_n^*\}, \text{ где } C_W^* \subset C^*$$

$$C_W^* \in W_a, C^* \in W_b$$

В результате получаем прецеденты, которые являются подмножеством известной зоны аномалий:

$$P_1 = [\{x_1 \ x_2 \ \dots\}, \{x_1 \ x_2 \ \dots\}, \dots \{x_1 \ x_2 \ \dots\}]$$

$$P_2 = [\{x_1 \ x_2 \ \dots\}, \{x_1 \ x_2 \ \dots\}, \dots \{x_1 \ x_2 \ \dots\}]$$

...

$$P_n = [\{x_1 \ x_2 \ \dots\}, \{x_1 \ x_2 \ \dots\}, \dots \{x_1 \ x_2 \ \dots\}]$$

Чтобы определить к какой аномалии принадлежат прецеденты проекта M^* , воспользуемся принятой метрикой близости $N(P_n, C^*)$. Затем, для определения пространственных характеристик построим границы новой зоны аномалий. Если для прецедента отсутствует по смыслу близкий прецедент, принимаем его статистически не значимым. Для таких прецедентов границы зоны аномалий не строятся.

Эксперимент. В ходе исследования проведен эксперимент, направленный на оценку эффективности предложенной модели на примере задачи определения зон аномалий исполнения логистического проекта в условиях неопределенности. Под условиями неопределенности рассматривался сценарий, при котором информация ограничена известными зонами аномалий из реализованных проектов и прецедентами проявления аномалий.

Для проверки модели использовалось программное обеспечение QGIS версии 3.42 и язык программирования Python.

Предположим, что имеется текущий ЛПП, в котором расположено 7 логистических центров, между которым построены маршруты (Рис. 3).

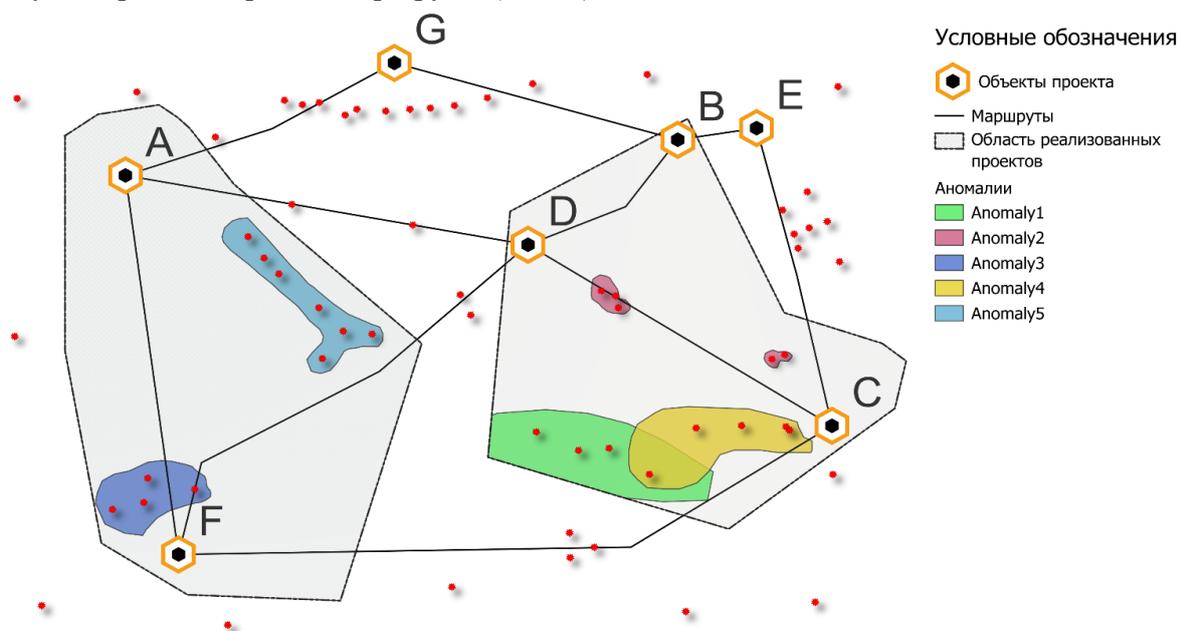


Рис. 3 – Схема проекта

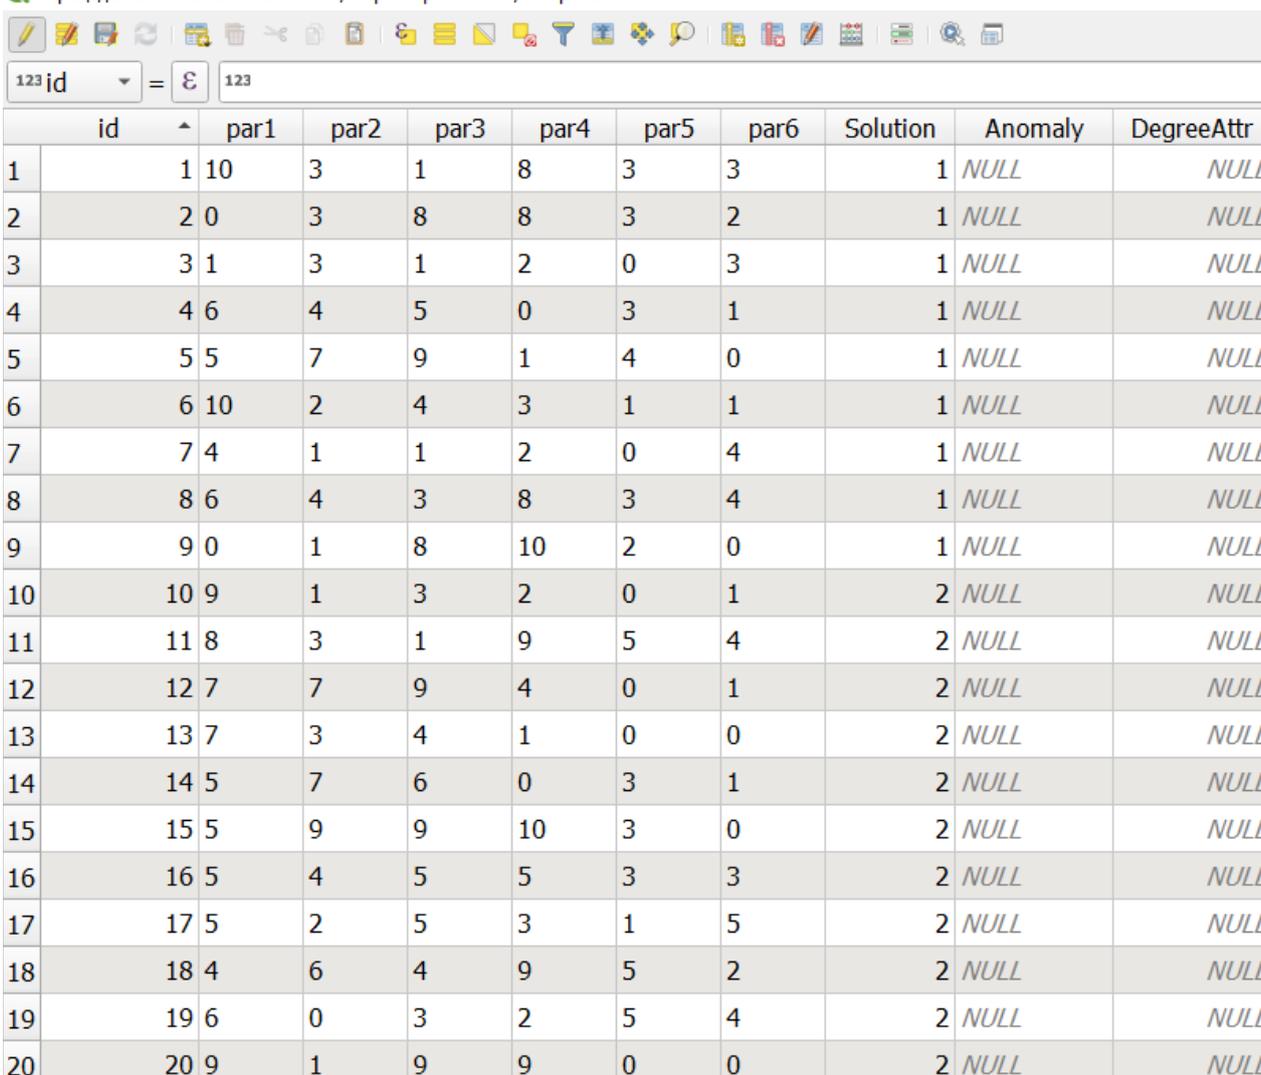
Исходя из информации по реализованным проектам нам известны 5 различных типов зон аномалий, а также 61 прецедент, связанный с ними. Считаем, что других типов зон аномалий в области текущего проекта нет. Прецеденты заданы в виде точечных объектов. Параметры прецедента заданы 6 случайными параметрами с помощью функции $\text{rand}(\min, \max)$:

$$\begin{aligned} \text{par 1} &= \text{rand}(0, 10); & \text{par 4} &= \text{rand}(0, 10); \\ \text{par 2} &= \text{rand}(0, 10); & \text{par 5} &= \text{rand}(0, 5); \\ \text{par 3} &= \text{rand}(0, 10); & \text{par 6} &= \text{rand}(0, 5) \end{aligned}$$

Аналогичным образом, каждому прецеденту выбирается одно из решений $\text{Solution} = \text{rand}(\min 1, \max 5)$.

В результате, таблица примет следующий вид (Рис. 4):

Q Прецеденты — объектов всего: 61, отфильтровано: 61, выбрано: 0



	id	par1	par2	par3	par4	par5	par6	Solution	Anomaly	DegreeAttr
1	1	10	3	1	8	3	3	1	NULL	NULL
2	2	0	3	8	8	3	2	1	NULL	NULL
3	3	1	3	1	2	0	3	1	NULL	NULL
4	4	6	4	5	0	3	1	1	NULL	NULL
5	5	5	7	9	1	4	0	1	NULL	NULL
6	6	10	2	4	3	1	1	1	NULL	NULL
7	7	4	1	1	2	0	4	1	NULL	NULL
8	8	6	4	3	8	3	4	1	NULL	NULL
9	9	0	1	8	10	2	0	1	NULL	NULL
10	10	9	1	3	2	0	1	2	NULL	NULL
11	11	8	3	1	9	5	4	2	NULL	NULL
12	12	7	7	9	4	0	1	2	NULL	NULL
13	13	7	3	4	1	0	0	2	NULL	NULL
14	14	5	7	6	0	3	1	2	NULL	NULL
15	15	5	9	9	10	3	0	2	NULL	NULL
16	16	5	4	5	5	3	3	2	NULL	NULL
17	17	5	2	5	3	1	5	2	NULL	NULL
18	18	4	6	4	9	5	2	2	NULL	NULL
19	19	6	0	3	2	5	4	2	NULL	NULL
20	20	9	1	9	9	0	0	2	NULL	NULL

Рис. 4 – Первые 20 прецедентов

В границах, реализованных ЛП расположены центры А, F, D, В, С. Маршруты AF, FD, FC, DC, проходят через границы аномалий.

Задача – построить тематическую карту зон аномалий для области текущего ЛП на основе информации о реализованных проектах.

Проверим прецеденты на соответствие области известных реализованных проектов. В результате был получен следующий набор прецедентов аномалий и значения их параметров:

Anomaly 1 = [(2, 10, 9, 9, 5, 0), (1, 6, 2, 0, 4, 4), (3, 10, 8, 7, 4, 4), (10, 3, 1, 8, 3, 3)];

Anomaly 2 = [(2, 5, 3, 8, 0, 0), (5, 7, 6, 0, 3, 1), (4, 6, 4, 9, 5, 2)], (8, 5, 2, 1, 1, 2), (4, 10, 9, 3, 4, 4)];

Anomaly 3 = [(1, 6, 2, 0, 4, 4), (2, 4, 2, 9, 0, 3), (6, 8, 4, 5, 1, 5), (10, 9, 0, 10, 5, 0), (5, 3, 5, 4, 5, 1)];

Anomaly 4 = [(2, 8, 8, 1, 5, 5), (10, 2, 4, 3, 1, 1), (6, 4, 3, 8, 3, 4), (3, 0, 4, 8, 5, 3), (0, 5, 5, 1, 3, 1), (5, 2, 5, 3, 1, 5), (0, 1, 8, 10, 2, 0)];

Anomaly 5 = [(6, 4, 5, 0, 3, 1), (6, 0, 3, 3, 0, 0), (5, 10, 2, 0, 2, 0), (8, 0, 0, 9, 5, 2)]

В данном эксперименте, в качестве метрики близости была использована мера сходства по Хэммингу, как наиболее приемлемая:

$$S(C, T) = \frac{n_{CT}}{n}$$

где n_{CT} – число совпадающих признаков (параметров) у прецедента С и ситуации Т, n – общее количество признаков.

Определяем к какой зоне ближе всего будет расположен прецедент. Для этого сравниваем прецеденты с набором прецедентов зоны аномалий (Рис. 5).

Прецеденты — объектов всего: 61, отфильтровано: 61, выбрано: 0

	id	par1	par2	par3	par4	par5	par6	Solution	Anomaly	DegreeAttr	CaseAnomal
1	1	10	3	1	8	3	3	1	Anomaly1	1,000	истина
2	2	0	3	8	8	3	2	1	Anomaly1	0,5	ложь
3	3	1	3	1	2	0	3	1	Anomaly1	0,5	ложь
4	4	6	4	5	0	3	1	1	Anomaly3	1,000	истина
5	5	5	7	9	1	4	0	1	Anomaly1	0,333	ложь
6	6	10	2	4	3	1	1	1	Anomaly5	1,000	истина
7	7	4	1	1	2	0	4	1	Anomaly2	0,333	ложь
8	8	6	4	3	8	3	4	1	Anomaly5	1,000	истина
9	9	0	1	8	10	2	0	1	Anomaly5	1,000	истина
10	10	9	1	3	2	0	1	2	Anomaly2	0,333	ложь
11	11	8	3	1	9	5	4	2	Anomaly3	0,5	ложь
12	12	7	7	9	4	0	1	2	Anomaly2	0,333	ложь
13	13	7	3	4	1	0	0	2	Anomaly2	0,333	ложь
14	14	5	7	6	0	3	1	2	Anomaly2	1,000	истина
15	15	5	9	9	10	3	0	2	Anomaly4	0,5	ложь
16	16	5	4	5	5	3	3	2	Anomaly3	0,5	ложь
17	17	5	2	5	3	1	5	2	Anomaly5	1,000	истина
18	18	4	6	4	9	5	2	2	Anomaly2	1,000	истина
19	19	6	0	3	2	5	4	2	Anomaly5	0,5	ложь
20	20	9	1	9	9	0	0	2	Anomaly1	0,5	ложь

Рис. 5 – Результаты сравнения прецедентов

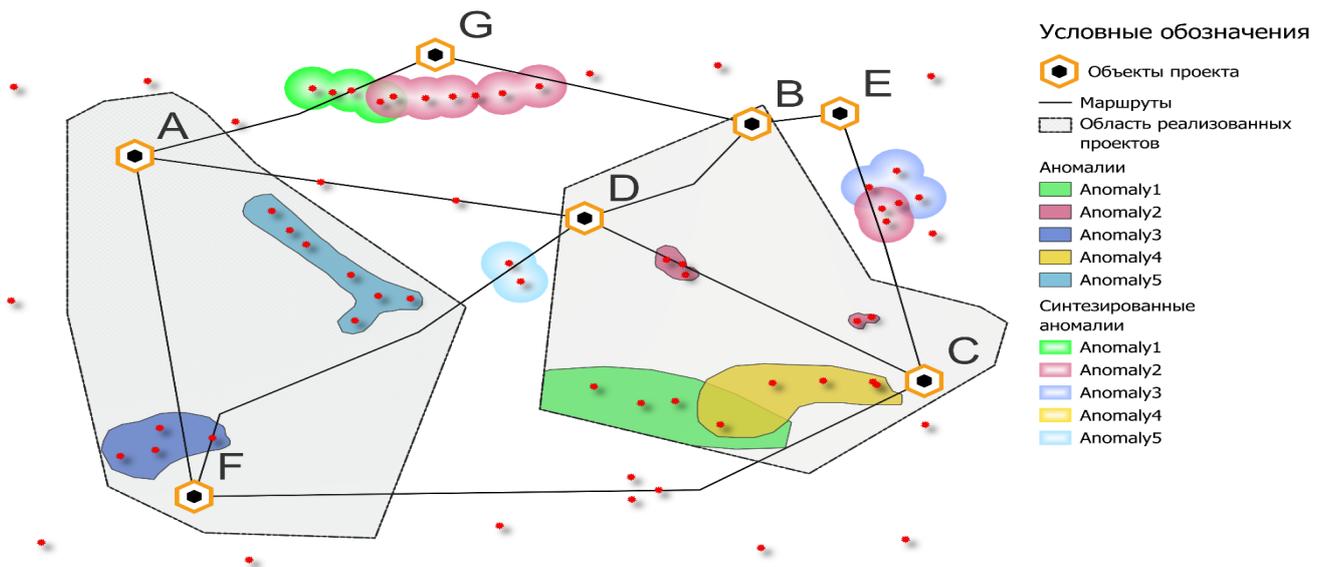


Рис. 6 – Синтезированные и известные зоны аномалии

Построим границы аномальной зоны с помощью операции «буфер» (Рис. 6).
В качестве метрики смысловой близости прецедентов используем Евклидову метрику:

$$d = \sqrt{\sum_{k=1}^n (p_k - q_k)^2}$$

Порог смысловой близости определим, как наименьшее расстояние, в пределах которого прецеденты могут считаться близкими. Порог смысловой близости соответствует размеру буфера.

Таким образом, в пределах области текущего ЛП были построены 5 синтезированных зон аномалий. Через них проходят маршруты FD, EC, AG, GB. Новые синтезированные зоны могут быть использованы для поиска зон аномалий в других проектах.

Результаты выявления зон аномалий текущего ЛП также могут быть уточнены за счет новых данных о прецедентах (Рис. 7). Благодаря дополнительным прецедентам в Anomaly 4, были синтезированы две новые зоны аномалий. Также, в проект могут быть дополнительно интегрирована информация о зонах аномалий из прочих ЛП.

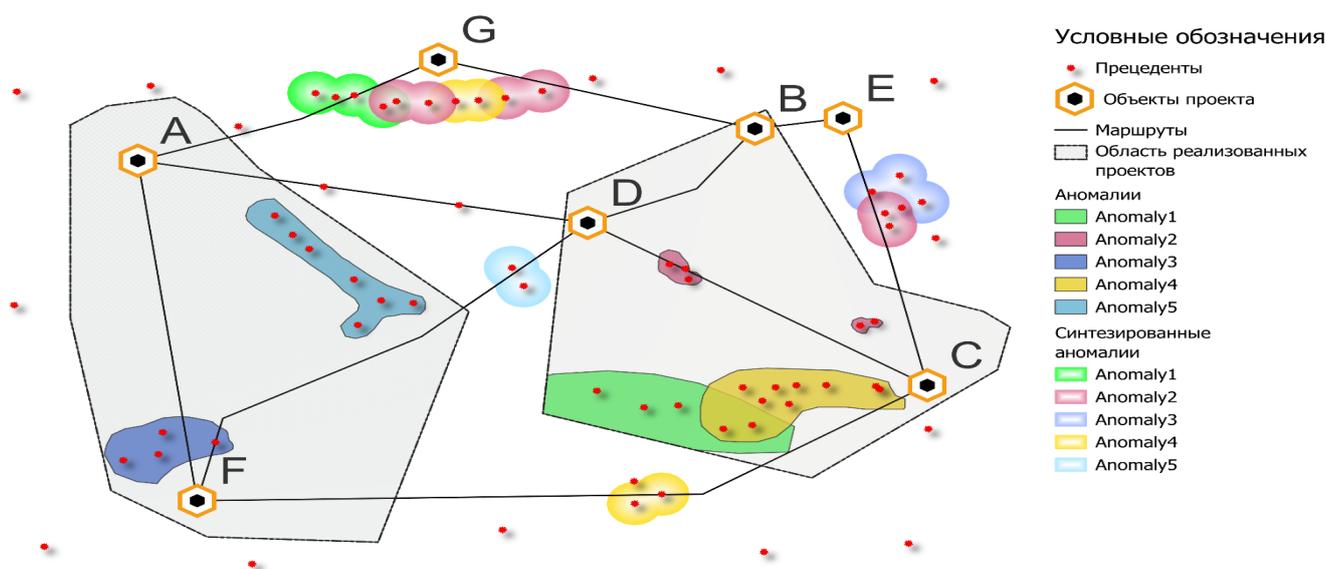


Рис. 7 – Зоны аномалий после добавления дополнительных прецедентов

Дальнейший анализ может быть посвящен выбору оптимального маршрута с учетом свойств ситуации на момент движения и прецедентами, составляющими зону аномалий.

Полученные результаты демонстрируют возможность использования модели для переноса информации из реализованных проектов с целью определения зон аномалий. Синтезированные аномалии становятся частью соответствующей базы данных и могут быть использованы для поиска аномалий в других проектах. При добавлении новых сведений результат может быть уточнен, что обеспечивает гибкость и адаптивность анализа. Таким образом, цель эксперимента достигнута.

Заключение

В работе проведено исследование по использованию картографического представления логистического проекта для построения тематической карты покрытия зонами аномалий. Разработана модель переноса информации о зоне проявления аномалий из одной области проекта в другую на основе обобщения известных прецедентов.

Предложенная модель предлагает ряд преимуществ:

1. Наглядная визуализация. Результат анализа зон поддается интуитивному манипулированию и может быть представлен различными методами визуализации (Тепловая карта, 3D-визуализация).
2. Возможность перенести знание в другое пространство. Для переноса используются известные прецеденты, расположенные в пределах области проекта. Их роль состоит в оценки близости текущей ситуации к определенному классу.
3. Построение самообучающейся системы. В ходе процессов анализа и переноса знаний, в системе накапливается информация о прецедентах. Проведенный эксперимент демонстрирует изменение результатов переноса знания при добавлении новых прецедентов и сведений о ранее реализованных проектах.
4. Ручное манипулирование информацией в области реализации проекта. Предложенная модель допускает участие пользователя (эксперта) для уточнения результатов анализа и добавление новых сведений. Он может выбрать другую метрику близости, изменить

параметры для расчета смысловой близости прецедентов. Также он может внедрить иную функцию визуализации в зависимости от поставленной задачи.

В отличие от существующих решений новая модель в полной мере рассматривает фактор пространственного распределения прецедентов. На основе отношений прецедента в пространстве определяются параметры для проведения рассуждений при построении зон. Рассуждения выполняются на основе дедуктивного вывода от известного общего знания о классе ситуаций к частным случаям. Такой тип рассуждений обеспечивает необходимый уровень достоверности решений в условиях неполноты и неопределённости информации.

Дальнейшие исследования будут посвящены расширению модели переноса знаний в условиях отсутствия точных границ.

Список использованной литературы

1. Мусайбеков А. Г., Хабибулин Р. Ш., Ухатов В. С. Анализ результатов поиска и сходимости прецедентов в системе поддержки управления ликвидации пожаров и чрезвычайных ситуаций // *Современные проблемы гражданской защиты*. – 2020. – № 1(34). – С. 4–15.
2. Дли М. И., Соколов А. М., Воротилова М. Ю. Построение локальных нечетких моделей для ситуационного управления сложными объектами на основе прецедентов // *Программные продукты и системы*. – 2025. – № 3.
3. Рашевский Н. М., Руденко И. Е., Соколов Д. А., Феклистов В. А., Якунин О. А. Разработка системы поддержки принятия решений на основе рассуждения по прецедентам по оценке безопасности участка транспортной системы города // *Информатика, вычислительная техника и управление (ИВД)*. – 2022. – № 7 (91).
4. Рожко А. И., Ханова А. А. Концептуальная структура системы управления транспортно-логистическим проектом на основе имитационного моделирования // *Вестник АГТУ. Серия: Управление, вычислительная техника и информатика*. – 2022. – № 1.
5. L. Marzantowicz, “The Impact of Uncertainty Factors on the Decision-Making Process of Logistics Management,” *Processes*, vol. 8, no. 5, p. 512, 2020. DOI: 10.3390/pr8050512
6. Беляков С. Л., Боженюк А. В., Белякова М. Л. Прецедентный анализ геоинформационных моделей проектов логистики // *Наука и технологии железных дорог*. – 2019. – № 2.
7. K. Guo, “Design of Human-Machine Collaborative Decision Support System in Emergency Logistics Scenarios,” *Int. J. Glob. Econ. Manag.*, vol. 7, no. 3, pp. 98–106, 2025. DOI: 10.62051/ijgem.v7n3.10.
8. I. Jażdżewska and K. Żerek, “A spatial analysis of one of the regional logistics clusters in central Poland using GIS,” *Environ. Socio-Econ. Stud.*, vol. 12, no. 2, pp. 48–61, 2024. DOI: 10.2478/environ-2024-0012.
9. K. R. Mudunuru, R. Remala, and S. K. Nagarajan, “Leveraging IoT and Data Analytics in Logistics: Optimized Routing, Safety, and Resource Planning,” *Int. J. Comput. Trends Technol.*, vol. 72, no. 7, pp. 101–107, 2024. DOI: 10.14445/22312803/IJCTT-V72I7P113.
10. A. Robinson, “Geovisual Analytics,” in *The Geographic Information Science & Technology Body of Knowledge*, J. P. Wilson, Ed., 3rd Quart. 2017. [Online]. Available: <https://doi.org/10.22224/gistbok/2017.3.6>.
11. C. Y. Krishna, “AI-Powered Supply Chain Optimization: Enhancing Demand Forecasting and Logistics,” *J. Comput. Sci. Technol. Stud.*, vol. 7, no. 4, pp. 792–801, 2025.
12. J. Mašek, L. Duricova, and J. Čamaj, “Analysing factors influencing railway accidents: A predictive approach using multinomial logistic regression and data mining,” *PLoS One*, vol. 20, no. 10, p. e0256789, 2025.
13. J. Li et al., “ChatSync: Large Language Model Enabled Spatial-Temporal Knowledge Reasoning for Production Logistics Synchronization,” *IEEE Internet Things J.*, vol. 12, no. 22, pp. 47499–47518, 2025. DOI: 10.1109/IJOT.2025.3603073.
14. U. Olmez et al., “Evaluation of logistics risk factors with BWM method; Sivas province example,” *Pesqui. Oper.*, vol. 44, p. e26745, 2024. DOI: 10.1590/0101-7438.2023.043.00286745.
15. J. Jiao, Y. Liu, and C. Xie, “The Optimization Model of E-Commerce Logistics Distribution Path Based on GIS Technology,” *Adv. Multimedia*, vol. 2022, p. 1234567, 2022. [Online]. Available: <https://doi.org/10.1155/2022/1234567>.

16. M. K. Pasupuleti, “Predictive Relief Logistics Models for Earthquakes and Floods Based on Traffic, Weather, and Supply Chain Data,” *Int. J. Acad. Ind. Res. Innov.*, vol. 5, no. 4, pp. 142–150, 2025.
 17. Зорькин Д. Ю., Самофалова Л. В., Асанова Н. В. Муравьиный алгоритм на Python // *Известия ЮФУ. Технические науки.* – 2025. – № 1 (243).
 18. Кошуняева Н. В., Тутьгин А. Г. Сравнительный анализ эффективности использования метаэвристических методов моделирования для решения задачи коммивояжёра // *Моделирование и анализ данных.* – 2025. – Т. 15, № 3. – С. 76–93.
 19. Конев К. А. Машинное обучение для поддержки принятия решений в сфере качества на промышленном предприятии // *Экономика. Информатика.* – 2023. – № 3.
 20. G. Andrienko, N. Andrienko, G. Fuchs, and J. M. Cordero Garcia, “Clustering Trajectories by Relevant Parts for Air Traffic Analysis,” *IEEE Trans. Vis. Comput. Graphics*, vol. 24, no. 1, pp. 34–44, 2018. DOI: 10.1109/TVCG.2017.2744322.
 21. T. Li et al., “HGeoKG: A Hierarchical Geographic Knowledge Graph for Geographic Knowledge Reasoning,” *ISPRS Int. J. Geo-Inf.*, vol. 14, no. 1, p. 18, 2025.
 22. R. Pierdicca, N. Muralikrishna, F. Tonetto, and A. Ghianda, “On the Use of LLMs for GIS-Based Spatial Analysis,” *ISPRS Int. J. Geo-Inf.*, vol. 14, no. 10, p. 401, 2025.
 23. Иванова Н. В., Белов В. С., Самаркин А. И. и др. Картографический анализ экстренных вызовов на дорожно-транспортные происшествия для оптимизации работы службы скорой медицинской помощи // *Вестник Псковского государственного университета. Серия: Естественные и физико-математические науки.* – 2023. – Т. 16, № 2. – С. 114–129.
 24. Беляков С. Л., Израилев Л. А. Геоинформационные модели аварийных ситуаций с пространственными обобщениями // *Известия ЮФУ. Технические науки.* – 2025. – № 1 (243). – С. 153–164. DOI: 10.18522/2311-3103-2025-1-153-164.
 25. N. Y. Uzun and A. Deran, “The importance of logistics costs in e-commerce businesses,” *Mersin Univ. J. Marit. Fac.*, vol. 7, no. 1, pp. 9–25, 2025. DOI: 10.47512/meujmaf.1699397.
 26. Маколова Л. В. Управление проектами в логистике: учеб. пособие. – Ростов-на-Дону: РГУПС, 2017.
-

УДК 656.223

ПРОИЗВОДИТЕЛЬНОСТЬ ТРУДА ЛОКОМОТИВНЫХ БРИГАД КАК КРИТЕРИЙ КАЧЕСТВА УПРАВЛЕНИЯ ПОЕЗДНОЙ РАБОТОЙ

Котенко Алексей Геннадьевич, руководитель центра ИИ ИНО, ФГБОУ ВО ПГУПС, Санкт-Петербург, Россия, Email: kotenko@pgups.ru

Котенко Оксана Владимировна, доцент кафедры УЭР, ФГБОУ ВО ПГУПС, Санкт-Петербург, Россия, Email: kotenko2106@yandex.ru

АННОТАЦИЯ

В работе на основе исследования вопросов комплексной оптимизации параметров работы локомотивного парка показана целесообразность включения в состав критериев качества управления поездной работой показателей производительности труда локомотивных бригад (ЛБ). Предложена формулировка критериев оптимальности производительности труда ЛБ в контексте управления работой локомотивного парка на полигоне. Показано, что решение проблемы оптимизации производительности труда ЛБ находится в тесной связи с задачей поиска оптимальных способов тягового обслуживания участков полигона в рамках принятой модели эксплуатации локомотивов. Особое внимание обращено на связь величины часовой выработки ЛБ и степенью развития функционала системы вождения поездов в режиме автопилота. Обозначен подход к определению рационального соотношения между производительной силой труда и его интенсивностью, и выделена его связь с оценкой пропорциональности использования режимов ручного и беспилотного вождения поездов.

Ключевые слова: организация движения, локомотивный парк, локомотивная бригада, производительность труда, поездная работа.

LABOR PRODUCTIVITY OF LOCOMOTIVE CREWS AS A CRITERION FOR THE QUALITY OF TRAIN OPERATION MANAGEMENT

Alexey G. Kotenko, Head of the Center for AI INO, FSBI VO PGUPS, St. Petersburg, Russia, E-mail: kotenko@pgups.ru

Oksana V. Kotenko, Associate Professor of the UER Department, Federal State Budgetary Educational Institution of Higher Education, St. Petersburg, Russia, E-mail: kotenko2106@yandex.ru

ANNOTATION

Based on the study of the issues of complex optimization of the parameters of the locomotive fleet, the expediency of including indicators of labor productivity of locomotive crews (LB) in the criteria for the quality of train operation management is shown. The formulation of criteria for optimal LB labor productivity in the context of managing the operation of the locomotive fleet at the landfill is proposed. It is shown that the solution to the problem of optimizing LB labor productivity is closely related to the task of finding optimal ways of traction maintenance of landfill sites within the framework of the accepted model of locomotive operation. Special attention is paid to the relationship between the hourly output of LB and the degree of development of the functionality of the train driving system in autopilot mode. An approach to determining the rational relationship between the productive power of labor and its intensity is outlined, and its relationship to the assessment of the proportionality of the use of manual and unmanned train driving modes is highlighted.

Keywords: traffic management, locomotive fleet, locomotive crew, labor productivity, train work.

Введение

С конца 2016 года параллельно внедрению центров управления тяговыми ресурсами (ЦУТР) осуществляется переход от региональных принципов управления эксплуатационной деятельностью к планированию и организации движения поездов на полигонах железнодорожной сети¹. Это связано с образованием протяженных направлений с электрической тягой, на которых участки обращения локомотивов расположены в пределах нескольких железных дорог; ростом грузопотоков со средней дальностью перевозки более четырех тысяч км и, как следствие, «с формированием значительного числа поездов, следующих без переработки на большие расстояния; повышением массы грузовых поездов; увеличением числа отправительских и технических маршрутов, следующих по согласованным между несколькими железными дорогами ниткам графика; выполнением ремонтных работ на протяженных линиях по принципу предоставления «окон» в створе» [1]. По сути, это переход на экстерриториальную схему управления перевозками в рамках укрупнённых полигонов, которая требует увеличения межремонтных пробегов подвижного состава, централизации контроля и формирования сквозных технологий организации перевозочного процесса. Модели, лежащие в основе таких технологий, должны включать в себя гибкие механизмы увязки целевых показателей и границ технологической ответственности участников перевозок [2]. На первом этапе эти механизмы формируются в ходе решения задачи по отысканию оптимальных параметров управления поездной работой, где в качестве критериев оптимальности выступают показатели среднесуточной производительности локомотивов. Вместе с тем постановка такой задачи, как указывалось ранее, «существенно ужесточает требования к четкости выражения и упорядоченности вычислительных процессов, формальному определению целей, пространственно-временных, технических, технологических и стоимостных ограничений. Для преодоления этих трудностей целесообразно использовать полимодельное логико-динамическое описание предметной области, направленное на реализацию возможности одновременного решения задачи синтеза технологии управления локомотивным парком и задачи планирования операций, потоков и ресурсов» [3]. Применить такое описание можно только на основе использования средств интеллектуального анализа данных [4]. С учетом этого, границы критериев оптимальности управления поездной работой могут быть расширены за счет показателей производительности труда локомотивных бригад (ЛБ). Основой для введения этих показателей в число критериев оптимальности является действующая система организации движения поездов, реализуемая на базе комплексного подхода к оптимизации параметров работы локомотивного парка.

1. Комплексная оптимизация параметров работы локомотивного парка

В задачах организации движения вопросам оптимального управления работой локомотивов и контингента ЛБ уделяется большое внимание.

Так технологический процесс составления графика движения поездов и разработки его нормативной базы² на стадии формирования основных нормативов включает не только разработку схем размещения локомотивного парка и участков работы локомотивов и локомотивных бригад, но и рассмотрение предложений по их изменению, сокращению числа технических стоянок и концентрации технических операций, а также по снижению времени на смену локомотивов и бригад. На стадии разработки графика предусматривается корректировка автоматизированной нормативной базы данных по перегонным временам хода, стоянкам поездов и пр. Проведение заключительных операций перед вводом в действие нового графика включает внесение изменений по тормозам, массе тары, длине подвижного состава.

¹Типовой технологический процесс работы полигона: утвержден распоряжением ОАО «РЖД» от 26.12.2016 № 2700р.

²Инструкция по разработке графика движения поездов в ОАО «РЖД»: утверждена распоряжением ОАО «РЖД» от 28.12.2023 № 3362/р.

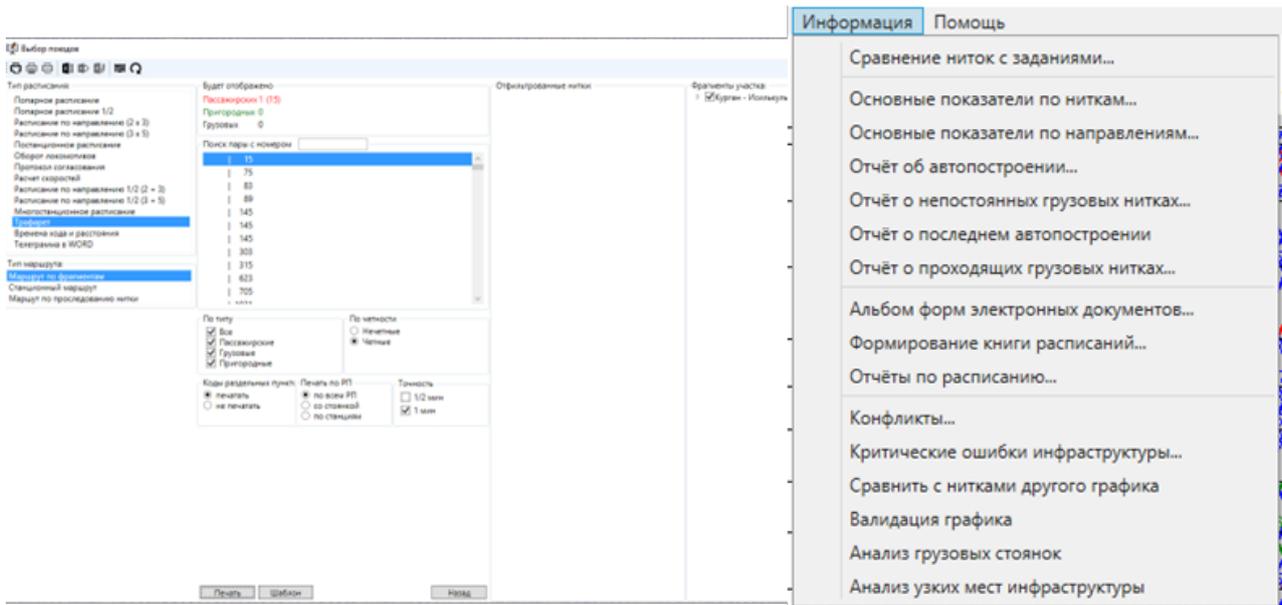


Рис. 1 – Автоматическая генерация отчетов по расписаниям, обороту локомотивов и других выходных форм при построении графика движения

В ходе этой работы генерируется множество, отчетов, ведомостей и других аналитических форм, необходимых для выработки оптимальных параметров (рис. 1). Например, в рамках прогноза показателей работы локомотивов и локомотивных бригад исследуются варианты усложненных схем оборота локомотивных бригад, включающих несколько пунктов оборота на участках их работы, наличие узловых станций в пунктах приписки или пунктах оборота. Выбираются пункты смены бригад с учетом рациональных режимов времени труда и отдыха. Формируются перечни удлиненных плеч и перечни технических станций, исключая стоянки для смены бригад на определенных маршрутах. Составляются графики оборота локомотивов и локомотивных бригад. Осуществляется расчет эффективного количества локомотивов и явочного штата бригад.

Для поддержания информации о графике движения в актуальном состоянии на каждые календарные сутки утвержденные ранее расписания корректируются: какие-то нитки могут сниматься, какие-то разрабатываться дополнительно, а какие-то корректироваться с учетом необходимости предоставления «окон».

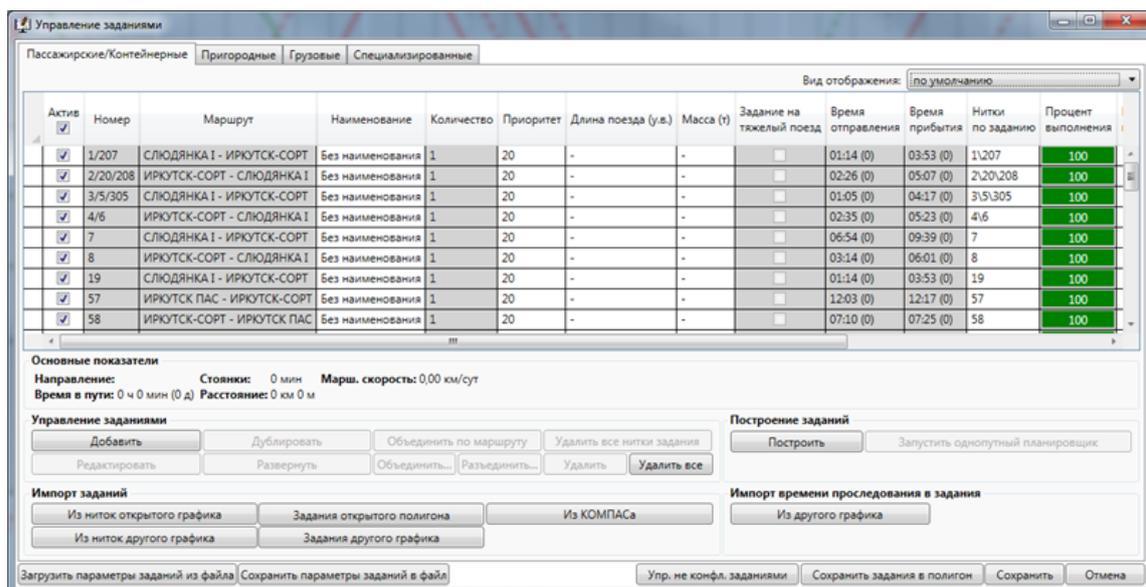


Рис. 2 – Задания на нитки в окне управления заданиями графика движения

В основе этой работы, как и при первоначальной разработке графика, лежат соответствующие задания (рис. 2), детализированные по времени отправления/прибытия в ключевых пунктах маршрутов, приоритету, нормам работы локомотивных бригад, длинам составов и массам поездов, технологиям работы на участках с большим уклоном (необходимости использования дополнительных локомотивов и бригад и пр.) и ряду других параметров.

Расчеты ведутся с проверкой соответствия заданных условий корректировки формируемым в графике. Активно используются инструменты анализа узких мест инфраструктуры – для выявления технических станций и участков полигонов, где наблюдается нехватка пропускной способности. А также инструменты увязки ниток, проложенных на соседних участках, и анализа грузовых стоянок. Ограничениями выступают данные о путевом развитии, обеспечении средствами сигнализации и связи станций и участков железнодорожной сети. Каждый разрабатываемый вариант нацелен на максимизацию качественных и количественных показателей графика в конкретные сутки (участковой, технической и маршрутной скоростей, размеров движения) с учетом всех существующих ограничений, включая «окна» и предупреждения об ограничении скоростей, и обеспечивает выполнение требований, касающихся: организации безопасности движения; рационального использования локомотивов, вагонов, пропускной способности линий и перерабатывающей способности станций; соблюдения норм работы локомотивных бригад; достижения минимальной продолжительности перевозок грузов и пассажиров; формирования наиболее благоприятных условий проезда пассажиров; экономичности перевозок.

При этом производительность локомотивов рассматривается в числе целевых показателей поездной работы, а оптимизация параметров управления работой локомотивного парка производится в разрезе его суточной производительности и, как показывает приведенный выше материал, в тесной увязке с другими аспектами решения задач оптимизации перевозочного процесса, в том числе, вопросами организации труда и отдыха ЛБ.

2. Критерии оптимальности производительности труда локомотивных бригад

Производительность труда ЛБ показывает степень эффективности трудового процесса, и может быть выражена через активность, оперативность и результативность работы персонала за конкретный промежуток времени. В этом смысле производительность труда ЛБ является продуктом деятельности и демонстрирует соотношение результатов и затрат как коллективного, так и индивидуального труда [5-6, 8].

Применительно к рассматриваемым вопросам удобно оперировать двумя показателями производительности труда ЛБ: индивидуальной производительностью отдельных бригад и коллективной производительностью их контингента.

Коллективная производительность труда контингента бригад на полигоне (P_c) определяется количеством тонно-километров брутто, отнесённым на численность контингента бригад:

$$P_c = f(\sum ql_p, SB_c) \quad (1),$$

где $\sum ql_p$ – выполненная перевозочная работа, т-км брутто; SB_c – численность контингента ЛБ [7].

Коллективная производительность труда ЛБ может быть легко увязана с критериями оптимальности суточной производительности локомотивов через показатель $\sum ql_p$, поскольку тесно связана с решением задачи отыскания оптимальных параметров управления работой локомотивного парка.

Такую задачу удобно представить в виде задачи о назначениях – фундаментальной задачи комбинаторной оптимизации, которую можно выразить кортежем

$$\langle Z, D, P, K, C, B \rangle \quad (2).$$

Решение этой задачи (постановка задачи подробно описана в [4]), которое направлено на выбор оптимальных способов тягового обслуживания участков полигона ($z_i \in Z$) в рамках принятой модели эксплуатации локомотивов D (как эталонной модели D_0 ($D_0 \in D$), определяемой графиком движения поездов и технологическим процессом работы полигона, так и множеством условий D_y для поддержания актуальности D_0), целесообразно производить методами линейного программирования B .

В качестве системы предпочтений P можно принять максимум производительности локомотивов при минимуме затрат на их эксплуатацию (включая перецепку, смену, резервные пробеги локомотивов и пр.). Такая система соответствует целям управления локомотивами на полигоне C , направленным на выполнение тонно-километровой работы минимальным парком путем повышения среднесуточных пробегов локомотивов и коэффициента использования их тяговой силы, снижения резервных пробегов [7].

Поиск оптимальных способов тягового обслуживания подчиняется ограничениям, устанавливаемым в процессе планирования работы парка на полигоне, касающимся размеров движения, числа локомотивов эксплуатируемого парка, продолжительности непрерывной работы локомотивов и величины их эксплуатационного резерва (Таблица 1), что предопределяет выбор целевых параметров качества K .

Таблица 1

Ограничения задачи поиска оптимальных параметров эксплуатации локомотивов

Ограничения	Формулировка
$N_r^{plan} \leq N_r^{graf}$	Число пар поездов, следующих по r -участкам N_r^{plan} , не должно превышать числа, предусмотренного графиком движения N_r^{graf}
$M_{max} = \{N_r^{plan}, k_{nr}\} \leq M_{ij}^{inv}$, k_{nr} – коэффициент потребности локомотивов на пару поездов на участке	Максимальная потребность локомотивов эксплуатируемого парка M_{max} не должна превышать количество локомотивов инвентарного парка j -х серий по i -м депо приписки M_{ij}^{inv}
$(L_{d-f}, v_m^{d-f}) \leq T_{ms}$, L_{d-f}, v_m^{d-f} – расстояние и маршрутная скорость поездов между станциями их формирования и расформирования	Время проследования локомотивов во главе поездов между станциями их формирования и расформирования не должно превышать нормативов времени на пробег локомотивов без технического обслуживания T_{ms}
$M^{res} \leq \{M_{ij}^{res}\}$	Количество локомотивов резерва M^{res} определяется числом резервных локомотивов j -х серий по i -м депо приписки

Для полигона в целом таким целевым параметром ($k \in K$) можно считать максимум среднесуточной производительности локомотива эксплуатируемого парка (W_l):

$$k = W_l = f\left(\sum q l_p, M_{ex}\right) \rightarrow \max \quad (3),$$

где $\sum q l_p$ – работа локомотивов т-км брутто на полигоне (по сути – выполненная перевозочная работа в пределах полигона); M_{ex} – эксплуатируемый парк локомотивов на полигоне.

Обозначенный контекст решения задачи выбора оптимальных параметров управления работой локомотивного парка на полигоне позволяет определить связь между критериями оптимальности суточной производительности локомотивов и коллективной производительности труда ЛБ.

Ранее отмечалось, что «на уровне управления особое внимание привлекают вопросы индивидуальной производительности труда бригад, выраженной через величину часовой выработки тонно-километров брутто:

$$P_c^{tkm} = f(Q_{br}, \sum NL, \sum t_c) \quad (4),$$

где Q_{br} – средний за данный период работы бригады вес поезда брутто, т; $\sum NL$ – выполненные бригадой за данный период поезда-километры, поезда-км; $\sum t_c$ – суммарное рабочее время бригады, час.» [7].

Характеризуя P_c^{tkm} следует отметить, что индивидуальная производительность труда ЛБ имеет двойственную природу, проявляя себя с одной стороны как «интенсивность» труда, с другой – как его «производительная сила». Первая характеризуется физиологическими затратами бригад, то есть уровнем напряжённости труда, вторая – уровнем применения техники и организации производственного процесса.

На начальном этапе анализа принято отождествлять P_c^{tkm} с производительной силой. При этом, среди специалистов «техничко-технологические факторы, влияющие на величину производительной силы труда ЛБ широко известны:

- простои и сверхурочные работы, следование ЛБ пассажирами, ожидание работы;
- система явки бригад;
- использование смешанного обслуживания грузовых и пассажирских поездов;
- работа по принципу накладных плеч;
- масса поездов;
- совмещение технического обслуживания и экипировки локомотивов;
- квалификация работников ЛБ и др.» [7].

На этапах дальнейшего анализа индивидуальную производительность труда ЛБ необходимо рассматривать с учетом его интенсивности. Опыт показывает, что «с позиций интенсивности производительность труда бригады можно представить величиной часовой выработки в поезда-километрах:

$$P_c^{km} = f\left(\sum NL, \sum t_c\right) \quad (5),$$

а основными факторами, определяющими ее величину, согласно принятому подходу считать:

- техническую скорость движения поездов;
- долю вспомогательного времени $\sum t_{aux}$ в общем рабочем времени бригады $\sum t_c$;
- коэффициент полезной работы бригады $\rho_c = f\left(\sum t_c, \sum t_{aux}\right)$, для сохранения которого при росте скорости движения наряду с сокращением $\sum t_{aux}$ требуется удлинять участки работы бригад» [7].

Однако, поскольку повышение интенсивности P_c^{tkm} связано с ростом напряжённости труда: увеличением времени нахождения бригады в движении, усилением внимания к обеспечению безопасности движения поездов при больших скоростях, и ограничивается физиологическим пределом расхода человеческой энергии – приемлемость величины производительности труда будет определяться рациональным соотношением между производительной силой и интенсивностью труда ЛБ при условии, что $P_c^{tkm} = optimum$.

Добиться рационального соотношения между P_c^{tkm} и P_c^{tkm} на практике оказывается не просто. Например, одним из факторов роста производительной силы является повышение массы грузовых поездов за счёт развития тяжеловесного движения, а технология вождения

поездов повышенной массы требует высокой квалификации работников бригад. При этом использование современных локомотивов приводит к тому, что бригады осваивают новые приёмы и способы вождения поездов [9-12]. Всё это позволяет улучшить качество труда работников бригад, повышая его производительную силу. В то же время, при увеличении гарантийных плеч безопасного следования вагонов с улучшенными характеристиками появляется возможность удлинять участки работы бригад до физиологически допустимой протяженности с увеличением времени их непрерывной работы. Кроме того, особые условия обслуживания тяжеловесного движения приводят к росту концентрации внимания и затрат физиологических усилий ЛБ, что также существенно повышает интенсивность труда [13].

Таким образом, критерии оптимальности производительности труда ЛБ должны формироваться на основе анализа индивидуальной производительности и могут быть выражены в виде

$$\begin{cases} P_c^{km} \leq P_c^{km,norm} \\ P_c^{tkm} \rightarrow max \end{cases} \quad (5),$$

где $P_c^{km,norm}$ – величина часовой выработки в поездо-километрах, установленная пределами физиологических норм.

Интересно, что в случае беспилотного вождения поездов величина $P_c^{km,norm}$ в (6) теряет смысл и содержание критериев оптимальности индивидуальной производительности труда существенно упрощается: и P_c^{tkm} , и P_c^{tkm} можно увеличивать настолько, насколько позволяют технические параметры.

Анализ факторов формирования этих критериев в разрезе функционала систем автоведения в вождении поездов может выявить наличие скрытых резервов управления поездной работой. Во-первых, это касается технической скорости движения поездов. Например, исследование кривых скоростей движения поездов, полученных в результате выполнения тяговых расчетов с соблюдением установленных времен хода и требований энергоэффективности, показывает, что добиться максимальных показателей индивидуальной производительности труда ЛБ удастся далеко не всегда (рис. 3).

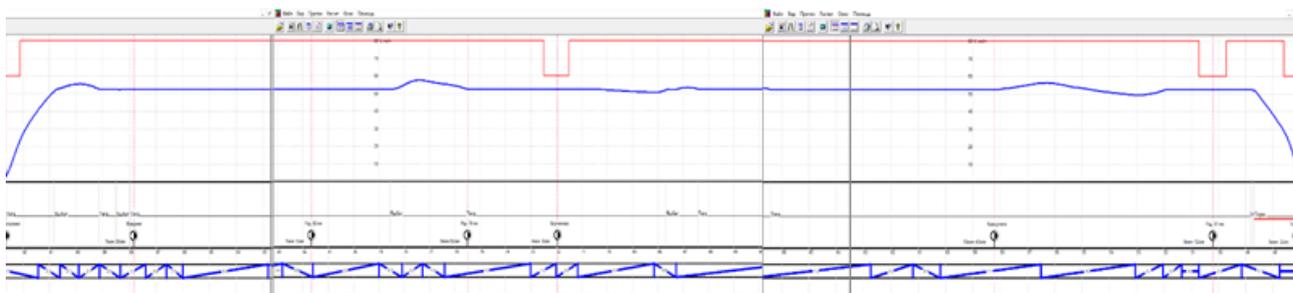


Рис. 3 – Фрагмент режимной карты ведения поезда, где синяя кривая – установленная расчетная скорость движения (52 км/ч), красная прямая – допустимая скорость (80 км/ч с двумя ограничениями 60 км/ч по ходу движения)

В этой связи, можно было бы исследовать разницу производительности на основе изменения кривых скорости на одних и тех же участках железнодорожных линий в ручном и беспилотном режимах вождения поездов. Ведь критерии оптимальной производительности систем автоведения в этом случае будут определяться исключительно величиной тонно-километровой работы:

$$\begin{cases} P_c = f(\sum ql_p, SB_c) \rightarrow max \\ P_c^{tkm} = f(Q_{br}, \sum NL, \sum t_c) \rightarrow max \end{cases} \quad (7).$$

Это, однако, требует решения вопросов оценки влияния ручного и беспилотного режимов вождения поездов на расчет траекторий движения. А это, в свою очередь, затрагивает вопросы идеологии вождения, где движение по перегонам подчинено зачастую исключительно

требованиям экономии ресурсов.

Критичным же при достижении результата здесь станет время от момента запуска режима автопилота до момента перехода на ручное управление.

Продолжительность этого времени (по аналогии с производственным конвейером) можно было бы регулировать путем выбора рациональной величины такта τ работы автопилота: $\tau = f(t_o, Q_{br}, \Sigma NL)$, где искомая длительность его работы (t_o), определяется показателями его производительности, выраженными через тонно-километровую работу (7).

Последнее дает возможность управлять характеристиками индивидуальной производительности труда ЛБ не только с учетом факторов, определяющих производительную силу и интенсивность труда, но и через время такта работы систем автоведения.

Идея более глубоко исследовать аспекты оценки производительности труда поездных ЛБ и производительности систем автоведения, опираясь на средства искусственного интеллекта и, прежде всего, средства интеллектуального анализа данных, для целей управления, является плохо изученной.

В то же время это направление лежит в одной плоскости с такими современным направлениями применения искусственного интеллекта в транспорте и логистике, как например, оптимизация управления характеристиками транспортных потоков в узких местах и точках стыков.

Множество работ посвящено формированию интеллектуального инструментария для решения проблемы «оптимизации операций по сбору и распределению контейнеров при перевозке морским и железнодорожным транспортом применительно к различным схемам портов, где решение связано с поиском путей оптимизации расписаний движения поездов и планов перевалки контейнеров для улучшения временной и пространственной координации между поездами и морскими судами, а целью является максимизация коэффициента прямой перевалки импортных/экспортных контейнеров и минимизация общего времени нахождения поездов в операционной зоне причалов» [14, 15] (В качестве одного из решений в этой области можно назвать систему Huawei's OptVerse AI Solver).

Не менее популярна идея оптимизации кросс-докинга, как «многоцелевой задачи планирования грузоперевозок» в крупных перегрузочных узлах с неопределенным временем прибытия транспортных средств, в том числе, в контексте концепции физического интернета [16].

Много усилий затрачивается на создание алгоритмов машинного обучения для решения проблем преодоления последствий сложных и чрезвычайных ситуаций. В части, например, «составления временных расписаний движения поездов после крупномасштабных стихийных бедствий, максимально приближенных к нормативным расписаниям на момент их пересмотра» [17].

Однако, практическое применение систем искусственного интеллекта, определяющих поездную работу, изначально подразумевает решение задачи определения рационального соотношения составляющих производительности труда ЛБ в различных режимах вождения поездов, направленное на минимизацию человеческого фактора при поиске оптимальных способов тягового обслуживания в рамках комплексной оптимизации параметров работы локомотивного парка.

Заключение

Производительность труда ЛБ «является необходимым условием повышения качества эксплуатационной работы, формирования уровня себестоимости перевозок, оценки показателей использования трудовых, материальных и финансовых ресурсов, и выступает в качестве основного источника экономического роста и повышения эффективности работы железных дорог» [7]. Результаты исследования показывают, что проблема повышения производительности труда ЛБ на укрупнённых полигонах может быть решена путем включения в состав базовых критериев качества управления поездной работой двух ключевых характеристик производительности: показателя тонно-километровой работы брутто, отнесённой на численность контингента бригад, и показателя часовой выработки бригады в поезде-километрах. Первая характеристика может использоваться как критерий оптимизации коллективной производительности контингента бригад на полигоне, вторая – индивидуальной

производительности отдельной бригады за единицу времени. В итоге рост коллективной производительности труда ЛБ будет определяться решением задачи отыскания оптимальных параметров управления работой локомотивного парка, а одним из основных путей повышения индивидуальной производительности труда ЛБ станет развитие систем автоведения и расширение функций беспилотного вождения поездов.

Список использованной литературы

1. Власенский А. А., Филипченко А. С. Логистика эксплуатационной работы железных дорог на основе полигонной технологии управления тяговыми ресурсами // *Логистика – евразийский мост: материалы XVI Междунар. науч.-практ. конф.*, Красноярск, 27–30 апр. 2022 г.: в 2 ч. – Ч. 1. – Красноярск: Краснояр. ГАУ, 2022. – С. 54–61.
2. Власенский А. А., Сотников Е. А. Повышение эффективности полигонных технологий управления тяговыми ресурсами // *Железнодорожный транспорт*. – 2015. – № 8. – С. 4–7. – ISSN 0044-4448.
3. Котенко А. Г., Котенко О. В. Динамические модели управления работой станций в рамках концепции киберфизических систем // *Автоматика на транспорте*. – 2020. – Т. 6, № 2. – С. 165–183.
4. Котенко О. В. Постановка задачи оптимизации параметров управления работой локомотивного парка на полигоне // *Проблемы безопасности на транспорте: материалы X Междунар. науч.-практ. конф.*, Гомель, 26–27 нояб. 2020 г.: в 5 ч. – Ч. 3. – Гомель: БелГУТ, 2020. – С. 134–138.
5. Лапидус Б. М. Проблемы и задачи повышения производительности труда в ОАО «РЖД» // *Бюллетень Объединённого учёного совета ОАО «РЖД»*. – 2016. – № 3. – С. 1–16.
6. Романцов А. Н. Экономическая сущность производительности труда в решении проблем её и повышения // *Модели, системы, сети в экономике, технике, природе и обществе*. – 2016. – № 4 (20). – С. 44–58.
7. Котенко О. В. Роль производительности труда локомотивных бригад в технологической регламентации перевозочного процесса // *Бетанкуровский международный инженерный форум: сб. тр. III форума*, Санкт-Петербург, 2–3 дек. 2021 г.: в 2 т. – Т. 1. – СПб.: Петерб. гос. ун-т путей сообщения, 2021. – С. 216–218.
8. Радостаева М. В. К вопросу о производительности труда // *Научные ведомости. Сер. Экономика. Информатика*. – 2018. – Т. 45, № 2. – С. 268–272.
9. Некрашевич В. И., Игнатов А. И. Методика расчета потребности в локомотивах при их оперативном секционировании и кратной тяге // *Вестник ВНИИЖТ*. – 2008. – № 2. – С. 24–30.
10. Некрашевич В. И., Ковалев В. Н., Сальченко В. Н. Месячное планирование парка локомотивов грузового движения // *Вестник НИИАС*. – 2012. – № 5. – С. 24–31.
11. Агеева М. А., Лаханкин Е. А., Подорин А. А., Кибанов Г. В. Автоматизация расчета потребности локомотивов и локомотивных бригад на график движения поездов с учетом индивидуальных особенностей полигона Октябрьской и Западно-Сибирской железных дорог в АСГОЛ-ГДС // *Интеллектуальные системы управления на железнодорожном транспорте. Компьютерное и математическое моделирование: сб. тр. VII науч.-техн. конф. «ИСУЖТ-2018»*. – М.: НИИАС, 2018. – С. 47–51.
12. Лаханкин Е. А. Планирование потребности в тяговых ресурсах. Организация работы локомотивов и локомотивных бригад // *Бюллетень Ученого Совета АО «ИЭРТ»*. – 2016. – С. 43–48.
13. Некрашевич В. И. Использование поездных локомотивов в грузовом движении. – Гомель: БелГУТ, 2001. – 270 с.
14. S. Ji et al., "Optimization of sea-rail intermodal container collection and distribution under novel port layout," *J. Rail Transp. Plan. Manag.*, vol. 33, p. 100503, 2025.
15. X. Wang and Z. Jin, "Collaborative optimization of multi-equipment scheduling and intersection point allocation for U-shaped automated sea-rail intermodal container terminals," *IEEE Trans. Autom. Sci. Eng.*, 2024. (Early Access).
16. F. Essghaier et al., "Fuzzy multi-objective truck scheduling in multi-modal rail-road physical internet hubs," *Comput. Ind. Eng.*, vol. 182, p. 109404, 2023.
17. S. Kat et al., "Rolling stock scheduling algorithm for temporary timetable after natural disaster," *Q. Rep. Railw. Tech. Res. Inst.*, vol. 65, no. 3, pp. 182–187, 2024.

УДК 656.13

МЕТОДЫ ИСПЫТАНИЙ ДЛЯ ОЦЕНКИ СООТВЕТСТВИЯ ПОДСИСТЕМЫ ДОРОЖНОГО ВИДЕОНАБЛЮДЕНИЯ В СОСТАВЕ ИНТЕЛЛЕКТУАЛЬНЫХ ТРАНСПОРТНЫХ СИСТЕМ

Свистельников Антон Андреевич, заместитель начальника управления методологии интеллектуальных транспортных систем, ФАУ «РОСДОРНИИ», Москва, Россия, E-mail: svistelnicovaa@rosdornii.ru

Малыхина Полина Вадимовна, начальник отдела научного обеспечения испытаний интеллектуальных транспортных систем, ФАУ «РОСДОРНИИ», Москва, Россия, E-mail: malykhinapv@rosdornii.ru

Григорьева Аделина Маратовна, главный специалист отдела сопровождения стандартизации интеллектуальных транспортных систем, ФАУ «РОСДОРНИИ», Москва, Россия, E-mail: zaharovaam@rosdornii.ru

Кумалов Тембулат Заурбекович, главный специалист отдела научного обеспечения испытаний интеллектуальных транспортных систем, ФАУ «РОСДОРНИИ», Москва, Россия, E-mail: kumalovtz@rosdornii.ru

АННОТАЦИЯ

Статья посвящена разработке методов испытаний подсистемы дорожного видеонаблюдения в составе интеллектуальных транспортных систем. Основное внимание уделено формированию подхода, позволяющего подтвердить выполнение подсистемой ее основных функций – формирование, передачу и отображение визуальной информации о дорожной обстановке. Предложена методика, основанная на определении зон обнаружения, распознавания и идентификации объектов наблюдения (пешеходов, транспортных средств и государственных регистрационных знаков) при соблюдении минимально необходимых технических характеристик оборудования. Результаты натурных испытаний, проведенных на пилотной зоне в Республике Татарстан, позволили установить количественные показатели зон наблюдения и оценить метрологические параметры погрешностей. Разработанный метод обеспечивает воспроизводимость результатов и может применяться при проектировании, вводе в эксплуатацию и эксплуатации подсистем дорожного видеонаблюдения.

Ключевые слова: интеллектуальные транспортные системы, дорожное видеонаблюдение, методы испытаний, оценка соответствия, зоны наблюдения, погрешность измерений.

TEST METHODS FOR ASSESSING THE COMPLIANCE OF THE ROAD VIDEO SURVEILLANCE SUBSYSTEM AS PART OF INTELLIGENT TRANSPORT SYSTEMS

Anton A. Svistelnikov, deputy head of the department of methodology for intelligent transport systems, FAI «ROSDORNII», Moscow, Russia, E-mail: svistelnicovaa@rosdornii.ru

Polina V. Malykhina, head of the scientific support department for testing intelligent transport systems, FAI «ROSDORNII», Moscow, Russia, E-mail: malykhinapv@rosdornii.ru

Adelina M. Grigoreva, deputy head of the department of methodology for intelligent transport systems, FAI «ROSDORNII», Moscow, Russia, E-mail: zaharovaam@rosdornii.ru

Tembulat Z. Kumalov, chief specialist of the scientific support department for testing intelligent transport systems, FAI «ROSDORNII», Moscow, Russia, E-mail: kumalovtz@rosdornii.ru

АННОТАЦИЯ

The article is devoted to the development of methods for testing the road video surveillance subsystem as part of intelligent transport systems. The main focus is on creating an approach that allows for the confirmation of the subsystem's ability to

perform its main functions, which include the generation, transmission, and display of visual information about the road situation. A methodology has been proposed based on the definition of detection, recognition, and identification zones for surveillance objects (pedestrians, vehicles, and license plates) while maintaining the minimum required technical specifications for the equipment. The results of field tests conducted in a pilot zone in the Republic of Tatarstan have allowed for the quantification of surveillance zones and the assessment of metrological error parameters. The developed method ensures the reproducibility of results and can be used in the design, commissioning, and operation of road video surveillance systems.

Keywords: intelligent transport systems, road video surveillance, test methods, conformity assessment, surveillance zones, and measurement errors.

Введение

В настоящее время подсистема дорожного видеонаблюдения в составе интеллектуальных транспортных систем (далее – ИТС) является одной из наиболее востребованных [1]. По результатам проведенного мониторинга на 2025 год по количеству периферийного оборудования ИТС на автомобильных дорогах общего пользования с большим отрывом лидируют детекторы транспорта в составе подсистемы мониторинга параметров транспортных потоков (23,6 тысяч устройств или 23,27% от общего количества¹), специальные технические средства, работающие в автоматическом режиме и имеющие функции фото- и киносъемки, видеозаписи, для обеспечения контроля за дорожным движением в рамках работы подсистемы контроля соблюдения Правил дорожного движения и контроля транспорта (20,4 тысячи устройств или 20,11% от общего количества), а также – видеокамеры в составе подсистемы дорожного видеонаблюдения (20 тысяч устройств или 19,73% от общего количества). При этом подсистема дорожного видеонаблюдения может быть реализована в составе ИТС, либо как отдельный компонент. Платные автомобильные дороги общего пользования и значительная часть УДС почти полностью охвачены дорожным видеонаблюдением, что позволяет обеспечить непрерывный контроль за дорожно-транспортной обстановкой. Немаловажным является и тот факт, что подсистема видеонаблюдения является важным источником информации для смежных подсистем ИТС, а также внешних информационных систем.

Увеличение количества видеокамер дорожного видеонаблюдения в качестве периферийного оборудования ИТС влечет за собой повышение требований к качеству их функционирования. Для этого необходимо подтвердить соответствие функциональных и технических характеристик установленным требованиям. В соответствии с федеральным законом [2] одной из основных форм подтверждения соответствия являются испытания. Сами испытания – это экспериментальное определение характеристик свойств объекта испытаний. Оценка соответствия проводится путем сравнения полученных результатов испытаний с требованиями, предъявляемыми к объекту испытаний.

1. Определение методов испытаний подсистемы дорожного видеонаблюдения

Основной задачей подсистемы дорожного видеонаблюдения (далее – ПДВ) является формирование, передача и отображение визуальной информации о дорожной обстановке на участке автомобильной дороги. Видеоинформация формируется посредством видеокамеры и отражает сцену видеонаблюдения. Под сценой наблюдения понимается пространство в поле зрения видеокамеры, включая все находящиеся в нем статические и динамические объекты, ограниченное углом обзора объектива видеокамеры. Так как основным субъектом ПДВ является оператор, то визуализация видеоинформации происходит на устройствах отображения информации: индивидуального или коллективного пользования.

Таким образом, показателем качества процесса формирования, передачи и отображения

¹Здесь и далее информация мониторинга, проведенного ФАУ «РОСДОРНИИ» в рамках работы по анализу развития интеллектуальных транспортных систем, оценке развития технологий и нормативного регулирования интеллектуальных транспортных систем Российской Федерации, актуальна на 15.09.2025

- мониторинг дорожно-транспортной ситуации на участке автомобильной дороги;
- выявление дорожных инцидентов в ручном режиме;
- выявление дорожно-транспортных происшествий (далее – ДТП) в ручном режиме;
- визуальная оценка транспортно-эксплуатационного состояния участка автомобильной дороги;
- визуальная оценка опасных метеорологических явлений на участке автомобильной дороги [3].

В единственном действующем на сегодня нормативном документе, определяющем технические требования к ПДВ (ПНСТ 893-2023), для оценки качества функционирования подсистемы введен показатель – точность выявления дорожно-транспортных ситуаций в зоне наблюдения видеокамеры. Данный показатель был впервые введен в британском стандарте [4] на системы видеонаблюдения охранного назначения и в дальнейшем использован в европейском стандарте [5] на охранные системы видеонаблюдения. Суть метода заключается в установлении минимальных требований к разрешающей способности изображения в зависимости от целей наблюдения. В соответствии с этим подходом для различных уровней детализации активностей, таких как обнаружение (detect), наблюдение (observe), распознавание (recognise), идентификация (identify), проверка (inspect) и мониторинг (monitor) определяется количество пикселей на метр размера объекта, а также его высота в процентах от экрана. Эти параметры позволяют формализовать требования к качеству изображения и служат основой для проектирования и оценки систем видеонаблюдения (Таблица 1).

Таблица 1

Уровни детализации и соответствующие им требования к разрешению (по данным EN 501327)

Категория активности	Разрешение, %	1080P	720P	...	Мм/пиксель
Inspect	400	150	250	...	1
Identify	100	40	60	...	8
Recognise	50	20	30	...	16
Observe	25	10	15	...	40
Detect	10	10	10	...	80
Monitor	5	5	5	...	–

ФАУ «РОСДОРНИИ» в рамках работ по созданию системы оценки соответствия ИТС разрабатывает методы испытаний и проводит их натурную апробацию на пилотной зоне ИТС в Республике Татарстан [6]. При разработке методов испытаний для подтверждения соответствия ПДВ ИТС мы столкнулись с тем, что на практике применение метода оценки качества функционирования этой подсистемы на основе показателя, связанного с точностью выявления различных видов активности в зоне наблюдения видеокамеры на основе анализа количества пикселей экранов средств отображения информации на объект наблюдения, не пригоден для качественной оценки функционирования ПДВ по следующим причинам:

- метод ориентирован на охранные системы видеонаблюдения, а не на дорожные;
- не учитывается влияние внешних факторов на качество изображения;
- отсутствие инструментов для применения методики;
- подтвержденная испытаниями практическая нереализуемость.

Кроме того, жесткие критерии EN 50132-7, где каждый пиксель должен строго соответствовать заданному шаблону, не позволяют провести корректную оценку пограничных случаев, когда однозначное решение невозможно (например, человек стоит на границе зоны наблюдения). В то же время, именно такие граничные условия составляют значительную долю реальных сценариев в дорожном видеонаблюдении.

Тогда была поставлена цель – разработать достаточно простой, но эффективный метод оценки качества функционирования ПДВ, который можно применять на практике в натуральных условиях без использования сложных методов и средств испытаний.

Для достижения этой цели были сформулированы несколько начальных условий:

- основными функциями ПДВ является формирование, передача и отображение визуальной информации о дорожной обстановке на участке автомобильной дороги;
- основные функции ПДВ направлена на человека-оператора;
- оператор ПДВ оценивает дорожно-транспортную ситуацию в зоне наблюдения видеокамеры на основании субъективных факторов;
- основные задачи в рамках работы оператора ПДВ направлены на выполнение задач, связанных с организацией и безопасностью дорожного движения, а также – с диспетчеризацией содержания автомобильных дорог.

Для эффективного выполнения своих задач оператор ПДВ должен иметь возможность в зоне наблюдения видеокамеры:

- определять дорожно-транспортную ситуацию на контролируемом участке автомобильной дороги;
- выявлять различные дорожные инциденты, в том числе ДТП, с участниками дорожного движения;
- определять существенные негативные факторы, влияющие на транспортно-эксплуатационное состояние дороги (снежные заносы, упавшие предметы на дорогу).

С практической точки зрения, перечисленные выше задачи связаны с наличием в зоне наблюдения пешеходов, транспортных средств или крупных предметов на проезжей части. При этом, для разных задач оператор должен определить наличие этих объектов наблюдения на сцене видеонаблюдения или различить какие-то их индивидуальные характеристики для принятия решения по применению соответствующего сценария управления.

Индивидуальные характеристики объектов наблюдения также можно категоризировать:

- по габаритам (посторонний предмет на проезжей части, пешеход, транспортное средство);
- по основной категории транспортного средства (мототранспортные средства, легковые автомобили, многоместные пассажирские транспортные средства, грузовые транспортные средства);
- по уникальным идентификационным признакам транспортного средства (государственный регистрационный номерной знак транспортного средства, далее – ГРЗ).

Очевидно, что объекты наблюдения и их индивидуальные характеристики на сцене видеонаблюдения будут определяться с заданным качеством на различном расстоянии от места установки видеокамеры. Тогда задача формирования показателей качества выполнения основных функций ПДВ сводится к определению дальности зон наблюдения для различных объектов наблюдения.

Для мониторинга дорожно-транспортной ситуации на контролируемом участке автомобильной дороги в первую очередь необходимо выявить на сцене видеонаблюдения объект наблюдения: пешехода, транспортное средство или крупный предмет на проезжей части. Наиболее уязвимым объектом из вышеперечисленных является пешеход [7]. Таким образом, если оператор сможет уверенно определить, что на сцене видеонаблюдения находится объект, сопоставимый по своим габаритам с пешеходом, без дальнейшей его классификации по другим индивидуальным характеристикам, то можно утверждать, что он в состоянии выполнять задачу мониторинга дорожно-транспортной ситуации.

Для более детального описания дорожно-транспортной ситуации оператор должен на сцене видеонаблюдения определить существенные индивидуальные характеристики объекта наблюдения. Очевидно, что основным участником дорожного движения на автомобильной дороге является транспортное средство, которое можно распознать и идентифицировать по следующим основным признакам: класс транспортного средства по категориям и ГРЗ транспортного средства.

Если оператор ПДВ на средствах отображения информации уверено определяет категорию транспортного средства, стоящего или движущегося на сцене видеонаблюдения, то мы можем говорить о распознавании объекта наблюдения. Если же оператор может определить ГРЗ транспортного средства, то это уже идентификация транспортного средства.

При разработке методики оценки качества функционирования ПДВ необходимо четко определить, что понимается под «категорией транспортного средства», поскольку этот термин используется как ключевой признак для распознавания объектов на сцене наблюдения. В настоящее время действующие нормативные документы предлагают различные подходы к классификации транспортных средств, однако их прямое применение в системах видеонаблюдения не всегда целесообразно.

В соответствии с Техническими регламентами [8,9] транспортные средства делятся на 5 основных категорий (М, N, L, O, T) и 13 подкатегорий, не считая отдельных положений по прицепах и полуприцепам. В то же время, Федеральный закон о безопасности дорожного движения [10] устанавливает 10 категорий и 6 подкатегорий механических транспортных средств.

На сегодняшний день классификация транспортных средств осуществляется по следующим критериям:

- по коэффициенту приведения транспортного средства к легковому автомобилю – применяется в расчетах пропускной способности дорог;
- по количеству осей транспортного средства, а также расстояния между ними – для контроля нагрузки на дорожное покрытие и весового контроля;
- по габаритной длине транспортного средства – влияет на режимы движения, выбор полосы, безопасность маневрирования;
- по массе транспортного средства – определяет допустимые маршруты, ограничения по мостам и сезонности.

При этом, указанные нормативные документы не учитывают все транспортные средства, например, не классифицированы гужевой транспорт и средства индивидуальной мобильности.

Для решения задачи распознавания транспортного средства в рамках функционирования ПДВ габаритные размеры [11] (длина, ширина, высота) являются наиболее устойчивым и надежным признаком, поскольку они:

- сохраняются при изменении освещенности;
 - могут быть оценены даже при частичном перекрытии объекта (например, деревьями или другими транспортными средствами);
 - меняются пропорционально масштабированию изображения.
- Распознавание ГРЗ движущегося транспортного средства средствами видеонаблюдения в ручном режиме требует отличных психофизиологических качеств оператора (реакция, память, стрессоустойчивость и т.п.), превышающих способности среднего человека.

Все перечисленные выше задачи определения объекта наблюдения возможны только при выполнении минимально необходимых технических требований к оборудованию в составе ПДВ (видеокамерам, средствам отображения информации) и телекоммуникационным сетям, передающим видеосигнал.

Учитывая все вышеизложенное, сформулируем условия для применения метода испытаний, с учетом сделанных выше уточнений.

1. Оператор должен определять в зоне наблюдения следующие категории транспортных средств:

- средства индивидуальной мобильности (электросамокаты, электроскейтборды, гироскутеры, сигвеи, моноколеса и т.п.);
- мототранспортные средства (мотоциклы, мопеды, мотовелосипеды и т.п.);
- легковые транспортные средства;
- грузовые транспортные средства;
- пассажирский транспорт;

– специальный транспорт.

2. Оператор должен определять ГРЗ неподвижного или движущегося с минимальной скоростью транспортного средства.

3. Технические средства ПДВ должны иметь минимально необходимые технические характеристики, определенные в соответствии с требованиями ПНСТ 893-2023 [12] и практического опыта эксплуатации ПДВ, не ниже:

- разрешение видеокамеры – не менее 1080р;
- частота кадров – не менее 25 кадров в секунду;
- возможность изменения фокусного расстояния для настройки зон наблюдения;
- разрешение экрана средств отображения информации – не менее 1920x1080;
- частота обновления кадров – не менее 60 Гц.

Для удобства введем новые понятия:

1. Зона обнаружения – участок сцены видеонаблюдения, характеризующийся расстоянием от места установки видеокамеры до объекта наблюдения, на котором оператор может визуально определить наличие объекта наблюдения без детального описания его характеристик.
2. Зона распознавания – участок сцены видеонаблюдения, характеризующийся расстоянием от места установки видеокамеры до объекта наблюдения, на котором оператор может визуально определить категорию объекта наблюдения.
3. Зона идентификации – участок сцены видеонаблюдения, характеризующийся расстоянием от места установки видеокамеры до объекта наблюдения, на котором оператор может визуально определить уникальные идентификационные признаки объекта наблюдения.

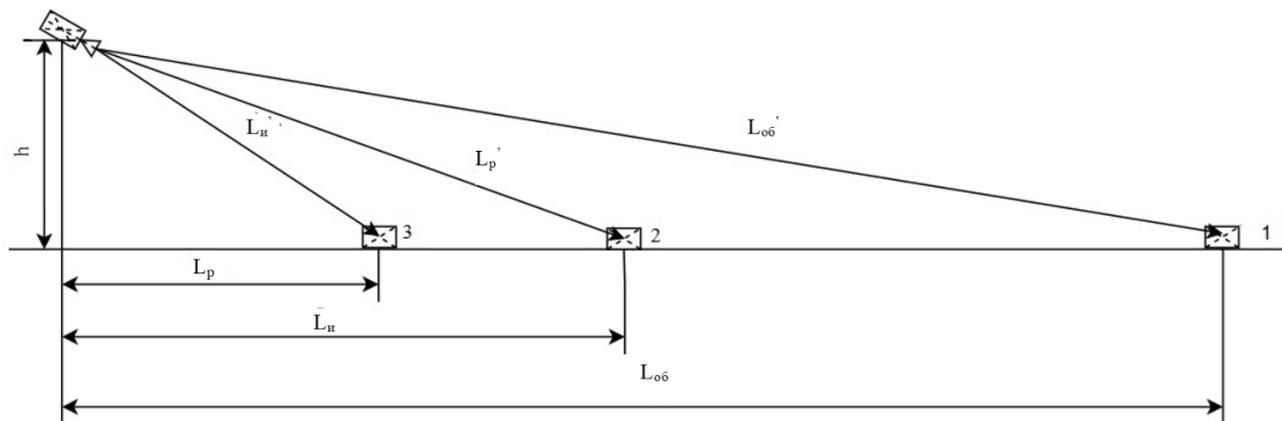


Рис 1. – Общая схема определения расстояний для каждой из зон

Обозначения на рисунке:

- 1 – объект наблюдения в зоне обнаружения;
- 2 – объект наблюдения в зоне распознавания;
- 3 – объект наблюдения в зоне идентификации;
- $L_{об}^{\prime}$ – расстояние от видеокамеры до объекта наблюдения в зоне обнаружения;
- $L_{р}^{\prime}$ – расстояние от видеокамеры до объекта наблюдения в зоне распознавания;
- $L_{и}^{\prime}$ – расстояние от видеокамеры до объекта наблюдения в зоне идентификации;
- $L_{об}$ – дальность зоны обнаружения;
- $L_{р}$ – дальность зоны распознавания;
- $L_{и}$ – дальность зоны идентификации;
- h – высота установки камеры.

Таким образом, оператор должен иметь возможность качественно определить:

- в зоне обнаружения – наличие пешехода;
- в зоне распознавания – категорию транспортного средства;
- в зоне идентификации – ГРЗ неподвижного (или медленно движущегося) транспортного средства.

По результатам натурных испытаний, проведенных ФАУ «РОСДОРНИИ» в 2025 году на пилотной зоне ИТС в Республике Татарстан, были определены количественные характеристики зон наблюдения при выполнении минимальных требований к оборудованию ПДВ:

- дальность зоны обнаружения – не менее 250 метров;
- дальность зоны распознавания – не менее 90 метров;
- дальность зоны идентификации – не менее 10 метров.

Испытания проводились в нормальных условиях [13]:

- при освещенности, соответствующей дневному времени суток (диапазон освещенности 10 000 – 100 000 лк);
- при хорошей метеорологической дальности видимости (более 200 м).

Погрешность испытаний составила:

- для зоны обнаружения ± 10 метров;
- для зоны распознавания ± 5 метров;
- для зоны идентификации ± 1 метр.

Таким образом, для оценки соответствия ПДВ в части выполнения основной функции по формированию, передаче и отображению визуальной информации о дорожной обстановке, необходимо провести испытания по следующему алгоритму (Рисунок 1).



Рис 2. – Алгоритм проведения испытаний

Следует отметить, что оценка качества распознавания объектов наблюдения является субъективной, поскольку основана на визуальном анализе видеоизображения оператором. Это вносит значительную долю случайной погрешности, обусловленную индивидуальными психофизиологическими особенностями оператора: скоростью реакции, внимательностью, утомляемостью, а также интерпретацией пограничных ситуаций (например, частичное перекрытие объекта, низкая контрастность, динамические помехи). Даже при одинаковых условиях наблюдения разные операторы могут давать несовпадающие оценки, что снижает повторяемость результата. Для минимизации влияния субъективного фактора и повышения надежности данных применяется многократное проведение испытаний с последующей статистической обработкой.

Для обработки результатов испытаний принимается допущение, что угол установки столба по отношению к поверхности дороги составляет 90° . Тогда нормируемое расстояние до объекта наблюдения в каждой из зон рассчитывается по известной теореме Пифагора для прямоугольного треугольника:

$$L'^2 = L^2 + h^2, \quad (1)$$

Применительно к рисунку формула (1) принимает следующий вид для каждой из зон:

$$L' = \sqrt{L^2 + h^2}, \quad (2)$$

где L' – нормируемое расстояние от места установки видеокамеры до объекта наблюдения;
 L – дальность зоны наблюдения (проекция нормируемого расстояния);
 h – высота установки камеры.

Обработка результатов испытаний проводится в целях получения статистически достоверной информации. Статистическая обработка результатов выполняется в соответствии с ГОСТ Р 8.736-2011 [14] в следующей последовательности:

- исключают известные систематические погрешности из результатов измерений;
- вычисляют оценку измеряемой величины;
- вычисляют среднее квадратическое отклонение результатов измерений;
- проверяют наличие грубых погрешностей и при необходимости исключают их;
- проверяют гипотезу о принадлежности результатов измерений нормальному распределению;
- вычисляют доверительные границы случайной погрешности (доверительную случайную погрешность) оценки измеряемой величины;
- вычисляют доверительные границы (границы) неисключенной систематической погрешности оценки измеряемой величины;
- вычисляют доверительные границы погрешности оценки измеряемой величины.

Систематическая погрешность возникает при проведении испытаний вследствие наличия погрешности средства измерения (лазерная рулетка, курвиметр) и погрешности нанесения линейной разметки.

Систематическая погрешность измерений рассчитывается по формуле:

$$\Delta = (L * \delta_{си}) + \delta_{лр}, \quad (2)$$

где Δ – погрешность результатов измерения, м;
 L – дальность зоны наблюдения (проекция нормируемого расстояния);
 $\delta_{си}$ – погрешность средства измерения;
 $\delta_{лр}$ – погрешность линейной разметки, м.

По результатам испытаний, проведенных ФАУ «РОСДОРНИИ», погрешность результатов измерения укладывается в доверительную вероятность 0,95.

Оценка измеряемой величины и среднее квадратическое отклонение рассчитывается для результатов измерений в серии испытаний. Количество испытаний в серии должно составлять не менее 7, в таком случае можно принять, что распределение случайной величины происходит по закону Стьюдента (t – распределение).

В случае обнаружения грубых погрешностей, их исключение производится с использованием критерия Граббса, который позволяет выявить выбросы в выборке при уровне значимости $\alpha=0,05$.

Валидация результатов испытаний проводится на основании сопоставления результатов испытаний ПДВ и значений ее основных характеристик с установленными требованиями.

Если функции и ее характеристики описаны в технической документации и подтверждаются выполнением основной задачи подсистемы с качеством, позволяющим оператору обнаружить объект, сопоставимый по размерам с пешеходом, распознать категорию транспортного средства или идентифицировать ГРЗ, в соответствующих зонах наблюдения, причем требования к дальности каждой зоны выполняются в пределах нормируемых значений, испытания считаются пройденными.

Если функции и ее характеристики описаны в технической документации, но качество выполнения не позволяет оператору достоверно выполнить хотя бы одну из указанных задач, а требования к дальности хотя бы одной зоны наблюдения не соответствуют нормируемым значениям, испытания считаются не пройденными.

В случаях, когда особенности назначения или конфигурации установки видеокамеры объективно не позволяют обеспечить наблюдение в одной или двух зонах (например, из-

за особенностей размещения оборудования или ограниченного сектора обзора), испытания проводятся в пределах зон, доступных для наблюдения, при условии соблюдения нормируемых значений для этих зон.

Заключение

Предложенный подход к подтверждению соответствия основных функций ПДВ по формированию, передаче и отображению визуальной информации о дорожной обстановке представляет собой практически применимую, объективную и воспроизводимую методологию, адаптированную к условиям эксплуатации современных ИТС.

В рамках метода реализован принцип постепенной декомпозиции оценки: от обнаружения объекта (например, пешехода) до его распознавания (по категории транспортного средства) и, при необходимости, идентификации (по ГРЗ). Особое внимание уделено обоснованности метрологической составляющей: учет систематических погрешностей измерений (средств измерения, линейной разметки), применение *t*-распределения Стьюдента для малых выборок и использование доверительных интервалов для повышения надежности результатов. Это обеспечивает статистическую достоверность даже при ограниченном числе испытаний, что важно для испытаний компонентов ИТС в натуральных условиях.

Разработанный метод испытаний позволяет проводить оценку качества функционирования ПДВ на различных стадиях ее жизненного цикла: при проектировании, вводе в эксплуатацию, техническом обслуживании и модернизации.

Список использованной литературы

1. Кирьян И. В., Трепалин В. А. Интеллектуальные транспортные системы видеонаблюдения: обзор литературы // *StudNet*. – 2022. – № 4. [Электронный ресурс]. – URL: <https://cyberleninka.ru/article/n/intellektualnye-transportnye-sistemy-videonablyudeniya-obzor-literatury> (дата обращения: 28.11.2025).
2. О техническом регулировании: федер. закон от 27.12.2002 № 184-ФЗ (ред. от 25.12.2023) [Электронный ресурс]. – Доступ из СПС «КонсультантПлюс».
3. Жанказиев С. В. Разработка проектов интеллектуальных транспортных систем: учеб. пособие. – М.: МАДИ, 2016. – 104 с. – EDN VUOCCP.
4. Alarm Systems – CCTV Surveillance Systems for Use in Security Applications – Part 7: Application Guidelines (BSI BS EN 50132-7). – British Standards Institution (BSI).
5. Alarm system – CCTV surveillance systems for use in security applications – Part 7: Application guidelines (EN 50132-7). – European Committee for Standardization (CEN).
6. Свистельников А. А., Ковешников А. А., Феофанов В. В., Малыхина П. В. Востребованность испытаний и исследований интеллектуальных транспортных систем и отдельных ее элементов // *Вестник НЦ БЖД*. – 2024. – № 3 (61). – С. 87–95.
7. T. Gandhi and M. M. Trivedi, “Pedestrian protection systems: Issues, survey, and challenges,” *IEEE Trans. Intell. Transp. Syst.*, vol. 8, no. 3, pp. 413–430, 2007. DOI: 10.1109/TITS.2007.903444.
8. О безопасности колесных транспортных средств: реш. Комиссии Таможенного союза от 09.12.2011 № 877 (ред. от 27.09.2023) (TP TC 018/2011) [Электронный ресурс]. – URL: <https://legalacts.ru/doc/reshenie-komissii-tamozhennogo-soiuza-ot-09122011-n-877-o/> (дата обращения: 21.08.2025).
9. О безопасности автомобильных дорог: реш. Комиссии Таможенного союза от 18.10.2011 № 827 (ред. от 12.10.2015) (TP TC 014/2011) [Электронный ресурс]. – URL: <https://legalacts.ru/doc/reshenie-komissii-tamozhennogo-soiuza-ot-18102011-n-827-o/> (дата обращения: 21.08.2025).
10. О безопасности дорожного движения: федер. закон от 10.12.1995 № 196-ФЗ (ред. от 07.07.2025) [Электронный ресурс]. – Доступ из СПС «КонсультантПлюс».
11. Свистельников А. А., Ковешников А. А., Феофанов В. В., Малыхина П. В., Торопов Н. Ю. Экспериментальное обоснование подходов к формированию методики испытаний подсистемы мониторинга параметров транспортного потока // *Дороги и мосты*. – 2024. – № 52/2. – С. 287–305.

12. ПНСТ 893-2023. Интеллектуальные транспортные системы. Подсистема видеонаблюдения и детектирования дорожно-транспортных происшествий и чрезвычайных ситуаций. Общие технические требования [Электронный ресурс] // Росстандарт. – URL: <https://www.rst.gov.ru/portal/gost/home/gost/> (дата обращения: 08.09.2025).
 13. ГОСТ Р 51672-2000. Метрологическое обеспечение испытаний продукции для целей подтверждения соответствия. – М.: Госстандарт России, 2000. – 19 с.
 14. ГОСТ Р 8.736-2011. Государственная система обеспечения единства измерений (ГСИ). Измерения прямые многократные. Методы обработки результатов измерений. Основные положения. – М.: Стандартиформ, 2011. – 4 с.
-

УДК: 629.4.077

КОНТРОЛЬ И ДИАГНОСТИКА ПОДВИЖНОГО СОСТАВА – ОТ ОДИНОЧНЫХ УСТРОЙСТВ ДО РОБОТИЗИРОВАННЫХ ДИАГНОСТИЧЕСКИХ КОМПЛЕКСОВ

Долгий Александр Игоревич, к.т.н., Генеральный директор, АО «НИИАС», Москва, Россия,
E-mail: a.dolgiy@vniias.ru

Кудюкин Владимир Валерьевич, Заместитель Генерального директора, АО «НИИАС», Москва, Россия,
E-mail: v.kudukin@vniias.ru

Хатламаджиян Агоп Ервандович, к.т.н., Заместитель Генерального директора, АО «НИИАС», Москва, Россия, E-mail: a.hatlamadzhiyan@vniias.ru

Шаповалов Василий Витальевич, к.т.н., Начальник Научно-технического комплекса программно-аппаратных комплексов диагностики инфраструктуры АО «НИИАС», Москва, Россия, E-mail: v.shapovalov@vniias.ru

АННОТАЦИЯ

В статье представлен комплексный анализ эволюции, современного состояния и перспектив развития систем контроля и диагностики железнодорожного подвижного состава. Проведен детальный обзор мировых тенденций, включая поэтапный переход от локальных датчиков к интегрированным интеллектуальным и роботизированным комплексам, основанным на технологиях машинного зрения, лазерного сканирования, предиктивной аналитики и искусственного интеллекта. Особое внимание уделено отечественным разработкам, в частности, Интегрированному посту автоматизированного приема и диагностики подвижного состава (ППСС) и его развитию. Описаны принципы гибридной модели обработки данных, архитектура и функциональные возможности ППСС, а также его модульное расширение, включая системы ПАК-М и «Элемент». Рассмотрены подходы к интеграции диагностических систем в информационно-управляющие комплексы станций, реализации предиктивного обслуживания и созданию роботизированных диагностических кластеров. Статья адресована специалистам в области железнодорожного транспорта, диагностики, автоматизации и информационных технологий.

Ключевые слова: диагностика подвижного состава, интегрированный диагностический комплекс, ППСС, предиктивная аналитика, искусственный интеллект, машинное зрение, роботизация, техническое обслуживание по состоянию, железнодорожный транспорт, АО «НИИАС».

MONITORING AND DIAGNOSTICS OF ROLLING STOCK – FROM SINGLE DEVICES TO ROBOTIC DIAGNOSTIC COMPLEXES

Alexander I. Dolgiy, Candidate of Technical Sciences, General Director, JSC NIIAS, Moscow, Russia,
E-mail: a.dolgiy@vniias.ru

Vladimir V. Kudyukin, Deputy General Director, JSC NIIAS, Moscow, Russia, E-mail: v.kudukin@vniias.ru

Agop Y. Khatlamadzhiyan, Candidate of Technical Sciences, Deputy General Director, JSC NIIAS, Moscow, Russia,
E-mail: a.hatlamadzhiyan@vniias.ru

Vasily V. Shapovalov, Candidate of Technical Sciences, Head of the Scientific and Technical Complex of Software and Hardware Complexes for Infrastructure Diagnostics of JSC NIIAS, Moscow, Russia, E-mail: v.shapovalov@vniias.ru

ANNOTATION

The article presents a comprehensive analysis of the evolution, current state and prospects for the development of control and diagnostic systems for railway rolling stock. A detailed review of global trends has been conducted, including a step-by-step transition from local sensors to integrated intelligent and robotic complexes based on machine vision, laser scanning, predictive analytics and artificial intelligence technologies. Special attention is paid to domestic developments, in particular, the Integrated Post for Automated Reception and Diagnostics of Rolling Stock and its development. The principles of the hybrid data processing model, the architecture and functionality of the PPSS, as well as its modular expansion, including the PAK-M and Element systems, are described. Approaches to the integration of diagnostic systems into information and control complexes of stations, the implementation of predictive maintenance and the creation

of robotic diagnostic clusters are considered. The article is addressed to specialists in the field of railway transport, diagnostics, automation and information technology.

Keywords: diagnostics of rolling stock, integrated diagnostic system, PPSS, predictive analytics, artificial intelligence, machine vision, robotics, condition maintenance, railway transport, JSC NIIAS.

Введение

Необходимость развития средств диагностики подвижного состава определяется ростом требований к качеству перевозочного процесса на железнодорожном транспорте, научно-техническим прогрессом и является одним из ключевых обеспечивающих элементов реализации концептуального подхода к созданию современной платформы управления перевозочным процессом в ОАО «РЖД» [1].

Основными направлениями совершенствования средств диагностики являются:

- создание систем, базирующихся на комплексировании разнородных диагностических признаков и интегральных критериях безопасности;
- развитие подходов к диагностированию на основе предиктивной аналитики с переходом к обслуживанию подвижного состава «по состоянию»;
- совершенствование процессов диагностирования узлов подвижного состава на основе новых физических принципов и современных методов моделирования, а также цифровой обработки данных.

Стационарные средства диагностирования подвижного состава на ходу поезда в настоящее время находятся на этапе бурного качественного развития, вызванного как растущими запросами и требованиями железнодорожной отрасли, так и появлением принципиально новых научно-технических подходов и средств. Такими средствами прежде всего являются машинное зрение, лазерное сканирование и триангуляционные измерения, применение высокоточных и высокочувствительных сенсоров физических величин (вибраакустических, тензометрических, тепловых и др.).

В рамках реализации стратегических задач цифровой трансформации железнодорожного транспорта в России, обозначенных в ОАО «РЖД», создание и внедрение интеллектуальных систем контроля и диагностики становится ключевым фактором обеспечения безопасности, надежности и экономической эффективности перевозочного процесса. Российская практика, основываясь на глубоком анализе мирового опыта, демонстрирует самостоятельный и конкурентоспособный путь развития, от модернизации унаследованных систем к созданию передовых комплексных решений.

Целью данной статьи является системное изложение эволюции технологий диагностики, анализ передовых зарубежных практик и, что наиболее важно, детальное освещение российских достижений в этой области. Особый акцент делается на результатах научно-технической деятельности АО «НИИАС», приведших к разработке и широкому внедрению на сети железных дорог России принципиально новой платформы – Интегрированного поста автоматизированного приема и диагностики подвижного состава на сортировочных станциях (ППСС). Данный комплекс представляет базис для формирования единой межхозяйственной платформы, обеспечивающей переход к малолюдным и безлюдным технологиям.

В статье последовательно рассматриваются: глобальные тренды и этапы развития диагностических систем; технологическая архитектура современных комплексов; роль искусственного интеллекта; региональные особенности; экономические и регуляторные аспекты. На этой основе подробно раскрывается отечественный опыт, включая концепцию гибридной модели обработки данных, структуру и функциональность ППСС, направления его развития (ПАК-М, «Элемент», модуль ДКБ), а также перспективы интеграции в цифровые станционные комплексы и создания распределенных диагностических кластеров. Таким образом, работа предоставляет целостное представление о современном уровне и будущих направлениях автоматизации процессов диагностики в российских условиях.

1. Подробный обзор зарубежных решений по контролю и диагностике подвижного состава

Анализ современного состояния зарубежных разработок в области диагностики железнодорожного подвижного состава выявляет масштабную технологическую трансформацию, охватывающую все аспекты технического обслуживания и контроля безопасности. Этот переход носит системный характер и представляет собой эволюцию от локальных измерительных процедур к глобальным интеллектуальным экосистемам управления жизненным циклом активов.

Исследования показывают, что ключевым драйвером изменений стало осознание экономической неэффективности и операционных рисков, присущих традиционным методам обслуживания, основанным на планово-предупредительных ремонтах и визуальном контроле. Новая парадигма предполагает непрерывный мониторинг технического состояния в реальном времени с прогнозированием остаточного ресурса компонентов [2, 6].

1.1 Смена технологических поколений диагностических систем

Исторический анализ демонстрирует четыре четко выраженных этапа развития.

На первом этапе (до 2000-х годов) доминировали ручные методы инспекции с использованием простых измерительных инструментов – шаблонов, микрометров, мерительных линеек. Этот период характеризовался высокой субъективностью оценок, низкой производительностью и практически полным отсутствием возможностей для выявления скрытых дефектов.

Второй этап (2000-2010-е годы) ознаменовался появлением стационарных путевых систем с базовым набором датчиков – детекторов перегрева букс (hot-box detectors), систем контроля габаритов, детекторов дефектов колес. Эти решения позволили автоматизировать контроль наиболее критических параметров и осуществлять круглосуточный мониторинг [2, 5].

Третий этап (2010-2020-е годы) принес качественный скачок в виде интегрированных мультисенсорных комплексов, объединяющих разнородные измерительные технологии в единые архитектуры. Именно в этот период получили широкое распространение путевые порталы полного цикла, оснащенные камерами высокого разрешения, тепловизорами, лазерными сканерами и рельсовыми датчиками нагрузки. Параллельно началось активное внедрение концепции бортовых инструментальных вагонов (IRV), превращающих обычные эксплуатационные поезда в мобильные диагностические лаборатории [8, 10].

Современный четвертый этап (2020-е годы и далее) характеризуется развитием автономных роботизированных систем и глубокой интеграцией искусственного интеллекта в процессы анализа данных. На смену системам, лишь обнаруживающим дефекты, приходят интеллектуальные платформы, способные прогнозировать развитие повреждений, оценивать остаточный ресурс и формировать прескриптивные рекомендации по оптимальному обслуживанию [9-10].

1.2 Технологическая архитектура современных диагностических комплексов

Современные системы диагностики представляют собой сложные киберфизические системы, архитектура которых включает несколько взаимосвязанных уровней. На нижнем сенсорном уровне располагается многообразие измерительных устройств, каждый из которых решает специфические задачи. Визуальные системы на основе высокоскоростных камер с разрешением, достаточным для обнаружения дефектов размером от нескольких миллиметров, обеспечивают мониторинг поверхности катания колес, боковых поверхностей вагонов, идентификацию инвентарных номеров [3-4]. Тепловизионные камеры, работающие в длинноволновом инфракрасном диапазоне, позволяют осуществлять бесконтактный контроль температурного состояния критических узлов – тормозных систем, буксовых узлов, подшипников, электрооборудования, а также контролировать уровень заполнения цистерн [2, 5].

Лазерные сканеры и системы структурированного света реализуют точное профилирование колесных пар с формированием их трехмерных моделей в реальном времени. Эти технологии обеспечивают измерение диаметра колес, толщины обода,

выявления отклонений от круглости (out-of-round), а также контроль габаритных параметров подвижного состава [3-4]. Акустические и ультразвуковые методы, включая анализ акустической эмиссии и импульсную ультразвуковую дефектоскопию, предназначены для выявления внутренних дефектов в материалах – усталостных трещин, расслоений, неметаллических включений [7].

Особое место занимают датчики деформации и силы, встраиваемые непосредственно в рельсовую структуру. Эти устройства измеряют динамические нагрузки от проходящего подвижного состава, выявляют перегрузки колес, неравномерное распределение массы по осям, что является критически важным для предотвращения повреждений как пути, так и самого подвижного состава [6].

Над сенсорным уровнем располагается платформа сбора и первичной обработки данных, реализующая принципы edge computing. Локальные вычислительные модули, размещаемые на диагностических постах, осуществляют фильтрацию сигналов, выделение признаков, предварительную классификацию и генерацию тревожных сообщений при обнаружении отклонений, превышающих установленные пороговые значения. Такая архитектура позволяет минимизировать объем передаваемых по сетям данных и обеспечить быстрое реагирование на критические ситуации даже при временной потере связи с центральными системами [2, 5].

Следующий уровень – сетевая инфраструктура, обеспечивающая агрегацию данных от множества разнесенных географически измерительных постов, их синхронизацию и передачу в централизованные системы анализа. Для этих целей используются как проводные (Ethernet, оптоволоконные линии), так и беспроводные технологии передачи данных, включая специализированные радиоканалы и сотовые сети [2, 5].

Верхний уровень системы представляет собой централизованную аналитическую платформу, выполняющую углубленный анализ накопленных данных, выявление долгосрочных трендов, корреляцию информации от различных источников, формирование прогнозных моделей и генерацию управляющих воздействий для систем планирования технического обслуживания.

1.3 Роль искусственного интеллекта и машинного обучения

Интеллектуализация диагностических систем является одним из наиболее значимых трендов последнего десятилетия. Методы машинного обучения и глубокого обучения применяются на различных этапах обработки данных, существенно повышая эффективность и достоверность диагностики [7, 10].

В задачах классификации визуальных дефектов (трещин, выщербин, коррозионных повреждений) наиболее эффективно зарекомендовали себя сверточные нейронные сети (CNN), способные автоматически выделять характерные признаки из изображений без ручного проектирования признаковых пространств. Эти архитектуры демонстрируют высокую точность при распознавании сложных паттернов, адаптируются к изменяющимся условиям освещенности и загрязненности поверхностей [10].

Для анализа временных рядов, получаемых от вибрационных, акустических и динамических датчиков, широко применяются рекуррентные нейронные сети, в частности архитектуры с долгой краткосрочной памятью (LSTM). Эти модели способны учитывать долгосрочные зависимости в последовательностях данных, что критически важно для прогнозирования развития дефектов и оценки остаточного ресурса оборудования [10].

Особое значение приобретают технологии слияния данных от множества разнородных датчиков (sensor fusion). Байесовские методы, глубокие архитектуры с множественными входами позволяют интегрировать информацию визуальных, тепловизионных, акустических и вибрационных каналов, существенно повышая достоверность диагностических заключений и снижая вероятность ложных срабатываний [10-11].

Генеративно-сопоставительные сети (GAN) находят применение в решении проблемы дисбаланса классов, характерной для диагностических задач, где примеры критических дефектов встречаются значительно реже нормальных состояний. Эти модели позволяют синтезировать дополнительные обучающие примеры редких дефектов, улучшая сбалансированность наборов данных и повышая качество обучения классификаторов [10].

1.4 Региональные особенности развития технологий

Анализ международного опыта выявляет существенные различия в подходах и приоритетах развития диагностических технологий в различных регионах мира, обусловленные историческими, экономическими и организационными факторами [4, 6-8].

В Европе доминирует системный подход, ориентированный на создание интероперабельных решений, интегрируемых в общеевропейскую железнодорожную систему. Стандартизация под эгидой Европейского союза железных дорог (ERA) и комитетов CEN/CENELEC охватывает не только технические характеристики оборудования, но и форматы данных, протоколы обмена, процедуры сертификации. Ключевым направлением развития является интеграция систем диагностики с Европейской системой управления железнодорожным движением (ERTMS), что создает единое информационное пространство для управления перевозочным процессом и техническим обслуживанием. Особое внимание уделяется концепции инструментальных вагонов (IRV), позволяющих осуществлять непрерывный мониторинг состояния инфраструктуры в процессе эксплуатации [8].

Североамериканский подход характеризуется прагматичностью и ориентацией на решение конкретных операционных задач, прежде всего – предотвращение сходов подвижного состава. На сети железных дорог США и Канады получили массовое распространение придорожные (wayside) диагностические системы, устанавливаемые на критически важных участках. Особое развитие получили акустические детекторы подшипников, системы контроля ударных нагрузок на колеса (Wheel Impact Load Detectors), тепловизионные системы обнаружения перегрева букс. Стандартизация в рамках Ассоциации американских железных дорог (AAR) обеспечивает совместимость оборудования различных производителей. Крупнейшие операторы (BNSF, Union Pacific, Canadian National) активно внедряют программы предиктивного обслуживания, основанные на анализе больших данных и использовании IoT-платформ [6-7].

Азиатский регион, и особенно Китай, демонстрирует наиболее динамичное развитие и масштабность внедрения. Создание крупнейшей в мире сети высокоскоростных железных дорог потребовало разработки и реализации комплексных программ автоматизации технического обслуживания. Китайские решения отличаются высокой степенью интеграции – типичным примером являются автоматизированные станции приемки и диагностики (PRISM), устанавливаемые на входах в депо. Эти системы объединяют многолинейное структурированное освещение для контроля геометрии колес, высокоразрешающие камеры для выявления поверхностных дефектов, тепловизоры, лазерные сканеры для габаритного контроля [3-4]. Государственная поддержка способствует развитию собственных производителей диагностического оборудования и созданию законченных технологических цепочек.

Японский подход сохраняет фокус на достижении высочайших показателей надежности и точности, что особенно критично для высокоскоростных линий Shinkansen. Диагностические системы здесь отличаются прецизионностью измерений, развитыми алгоритмами обработки сигналов, глубокой интеграцией с системами управления движением. Особое внимание уделяется ультразвуковым методам контроля колесных пар и созданию роботизированных комплексов для автоматизированных депо [4].

1.5 Экономические аспекты внедрения

Переход к современным системам диагностики сопряжен со значительными инвестициями, анализ экономической эффективности которых требует комплексного подхода. Капитальные затраты (CAPEX) включают стоимость диагностического оборудования, несущих конструкций (порталов, платформ), вычислительной инфраструктуры, монтажа и пусконаладки, интеграции с существующими системами, обучения персонала. Стоимость базовых путевых систем начинается от нескольких сотен тысяч долларов, тогда как комплексные автоматизированные порталы могут требовать инвестиций в миллионы долларов. Роботизированные комплексы для депо относятся к наиболее капиталоемким решениям [10].

Операционные затраты (OPEX) включают техническое обслуживание и калибровку оборудования, расходные материалы, энергопотребление, лицензионные платежи за программное обеспечение, затраты на персонал для эксплуатации и анализа данных, обновление и модернизацию систем.

Прямые экономические выгоды от внедрения современных систем диагностики включают сокращение незапланированных простоев, снижение затрат на аварийные ремонты, оптимизацию графиков технического обслуживания, продление срока службы компонентов, уменьшение потребности в инспекционном персонале, экономию на запасных частях за счет своевременной замены. Косвенные выгоды проявляются в повышении надежности и доступности подвижного состава, улучшении репутации оператора, снижении рисков аварий, соответствии регуляторным требованиям, накоплении данных для долгосрочного планирования [10].

Оценка возврата инвестиций (ROI) зависит от множества факторов: масштаба внедрения, интенсивности эксплуатации, текущего уровня отказов, стоимости простоев, эффективности внедренных систем, организационной готовности к изменениям. Типичные сроки окупаемости составляют 2-5 лет для базовых систем мониторинга, 3-7 лет для комплексных автоматизированных решений, 5-10 лет для роботизированных систем с более высокой неопределенностью оценок [10].

1.6 Технические стандарты и регулирование

Развитие систем диагностики происходит в условиях ужесточающихся требований безопасности и стандартизации. Международные стандарты IEC 62278 (RAMS – надежность, готовность, ремонтпригодность и безопасность) и серия европейских стандартов EN 50126/128/129 задают общие рамки для разработки и внедрения систем, связанных с безопасностью железнодорожного транспорта. Стандарты ISO 9712 и EN 473 регламентируют квалификацию персонала неразрушающего контроля, тогда как ISO 17025 устанавливает требования к компетентности испытательных лабораторий [10].

В Европейском союзе технические спецификации интероперабельности (TSI) и требования Европейского агентства по железным дорогам (ERA) формируют детальные правила проектирования, сертификации и эксплуатации диагностического оборудования. В Северной Америке регулирование осуществляют Федеральная администрация железных дорог США (FRA) и Transport Canada, тогда как стандарты Ассоциации американских железных дорог (AAR) устанавливают отраслевые технические требования. В Азии действуют национальные системы стандартизации: GB стандарты в Китае, JIS в Японии, Indian Railway Standards в Индии [10].

Процесс сертификации диагностических систем включает валидацию проектной документации, испытания прототипов, полевые испытания, оценку соответствия стандартам безопасности, получение разрешения на эксплуатацию. Особое внимание уделяется квалификации персонала – обучению и сертификации операторов систем, специалистов по неразрушающему контролю, аналитиков данных [10].

1.7 Перспективы и направления развития

Будущее развитие систем диагностики подвижного состава будет определяться несколькими ключевыми трендами. В краткосрочной перспективе (1-3 года) ожидается дальнейшее распространение интегрированных мультисенсорных систем, расширение применения машинного обучения для анализа данных, увеличение числа внедрений бортовых инструментальных систем, развитие облачных платформ для управления данными мониторинга [10].

В среднесрочной перспективе (3-7 лет) прогнозируется коммерциализация роботизированных инспекционных комплексов для депо, широкое внедрение цифровых двойников подвижного состава, развитие прескриптивных систем обслуживания, предлагающих не только прогнозы, но и конкретные рекомендации по действиям, стандартизация протоколов обмена данными между различными системами, появление новых бизнес-моделей, таких как Monitoring-as-a-Service [9-10].

Долгосрочные перспективы (7+ лет) связаны с созданием полностью автономных систем диагностики и обслуживания, интеграцией с автономными поездами, разработкой самообучающихся систем, адаптирующихся к новым условиям эксплуатации, созданием роботизированных комплексов, способных выполнять не только диагностику, но и ремонтные операции, формированием глобальных платформ обмена данными и лучшими практиками [10].

Критическими факторами успеха на пути к полной автоматизации являются технологическая надежность и точность диагностических систем, интеграционная совместимость компонентов, масштабируемость решений, обеспечение кибербезопасности, поддержка руководства и наличие четкой стратегии, развитие компетенций персонала, культура, ориентированная на данные и инновации, экономическая обоснованность инвестиций и четкий расчет возврата инвестиций [2, 7, 10].

Таким образом, современные зарубежные решения в области контроля и диагностики подвижного состава представляют собой сложные интегрированные системы, объединяющие передовые сенсорные технологии, методы искусственного интеллекта и робототехнические платформы. Их внедрение позволяет осуществить переход от реактивного к предиктивному и прескриптивному обслуживанию, что обеспечивает существенное повышение безопасности, надежности и экономической эффективности железнодорожного транспорта. Успешная реализация таких проектов требует комплексного подхода, учитывающего технологические возможности, экономические ограничения, регуляторные требования и организационную готовность к трансформации процессов технического обслуживания.

1.8 История вопроса в России

Еще 15-20 лет назад многие из применяемых сегодня методов диагностирования подвижного состава казались фантастикой, а перечень диагностируемых узлов и параметров подвижного состава был крайне ограниченным. Набор средств контроля и диагностики включал в себя небольшое число приборов и устройств, которые были обособлены и работали независимо друг от друга.

Развитие средств диагностирования подвижного состава на ходу поезда начиналось с приборов обнаружения нагретых аварийных букс ПОНАБ (конец 60-х -70-е годы прошлого века) и ДИСК-Б (конец 70-х – середина 90-х годов прошлого века).

С появлением современных микропроцессорных устройств в 1998-2002 годах научно-производственным центром «Инфотэкс» (НПП «Инфотекс») были разработаны и внедрены комплекты технических средств для модернизации ПОНАБ (КТСМ-01) и ДИСК (КТСМ-01Д). В данной аппаратуре впервые была заложена возможность передачи результатов диагностики на соседние станции и в центральный диагностический пост благодаря использованию системы передачи данных линейных пунктов (СПД ЛП) на базе концентраторов информации КИ-6М.

Данные технические решения послужили основой для создания автоматизированной системы контроля подвижного состава (АСКПС), активное внедрение которой проводилось на сети железных дорог России в начале 2000-х годов.

Еще одним направлением развития средств диагностирования подвижного состава на ходу поезда стало внедрение устройств контроля габарита подвижного состава. Наиболее простым и эффективным способом выявления нарушений нижнего габарита стало применение устройства контроля схода подвижного состава (УКСПС). Несмотря на однократный принцип действия, основанный на изломе регистрирующего элемента частями подвижного состава, находящимися вне габарита, устройство активно внедрялось и продолжает эксплуатироваться в настоящее время.

На основе проведенного анализа международного опыта и технологических трендов в области контроля и диагностики подвижного состава становится очевидно, что мировая практика последовательно эволюционирует от применения отдельных датчиков и ручных методов к созданию комплексных, интегрированных и интеллектуальных систем. Зарубежные решения демонстрируют активный переход к автоматизированным стационарным порталам, бортовым инструментальным системам и, как наиболее перспективное направление, к мобильным роботизированным платформам, способным проводить автономную диагностику. Ключевыми драйверами этой трансформации выступают технологии машинного зрения, лазерного сканирования, предиктивной аналитики на основе искусственного интеллекта и стремление к переходу от планово-предупредительного обслуживания к обслуживанию по фактическому и прогнозируемому состоянию.

В этом глобальном контексте представляется крайне важным и своевременным детально рассмотреть отечественный опыт и достижения в создании современных диагностических комплексов. Активное развитие данного направления в России, в частности, масштабная научно-техническая деятельность АО «НИИАС» с начала 2000-х годов, привело к

формированию собственного, конкурентоспособного технологического пути. Начав с модернизации унаследованных систем, таких как ПОНАБ и ДИСК, отечественные специалисты создали и внедрили на сети ОАО «РЖД» принципиально новые решения, соответствующие мировому уровню. Центральным элементом этой работы стал Интегрированный пост автоматизированного приема и диагностики подвижного состава на сортировочных станциях (ППСС), который не только представляет собой законченный роботизированный диагностический комплекс, но и служит аппаратно-программной платформой для дальнейшего развития. Именно этот комплекс стал основой для единой межхозяйственной платформы, обеспечивающей переход на малолюдные технологии при техническом и коммерческом осмотре.

Таким образом, логичным продолжением обзора мирового опыта является подробное освещение российских разработок, демонстрирующих конкретную реализацию концепции интегрированной диагностики, начиная от гибридной модели обработки данных и заканчивая практическими результатами внедрения и перспективами создания распределенных диагностических кластеров.

2. Гибридная модель комплексирования диагностических данных

Эффективная централизованная обработка разнородной информации, полученной от диагностических систем различных типов, является для железнодорожного транспорта одной из наиболее востребованных проблем, решение которой оказывает значительный эффект как на экономические показатели функционирования железнодорожной инфраструктуры, так и на уровень безопасности железнодорожных перевозок.

Анализ современных тенденций развития отечественных и зарубежных информационно-диагностических систем свидетельствует о малой эффективности традиционного подхода к решению указанной проблемы, основанного на раздельном использовании одной или нескольких диагностических моделей с последующим объединением результатов по простым мажоритарным принципам или нескольким критериям.

Впервые при создании объекта диагностической инфраструктуры была создана гибридная модель единого интегрированного поста приема составов на сортировочной станции (ППСС), позволяющая реализовать новый подход к решению проблемы интеллектуальной централизованной обработки разнородной информации с использованием когнитивных сенсоров, снабженных логико-лингвистической прагматикой, способной объединять разнородные данные, полученные от разных источников информации, и вырабатывать на их основе адекватные диагностические решения относительно технического состояния подвижного состава и железнодорожной инфраструктуры.

Верхний уровень иерархической интеллектуальной системы осуществляет интеграцию полученных от подсистем частных оценок в единый показатель тревоги для конечного пользователя. Математическую основу верхнего иерархического уровня интеллектуальной системы составляют гранулярные логические семантики (рисунок 1).

Была разработана обобщенная иерархическая структурная схема единой интеллектуальной среды функционирования ППСС, отражающая все этапы процесса получения и интеллектуальной обработки информации в соответствии с предложенной гибридной моделью.

Повышение показателя подтверждаемости неисправностей, обусловленное внедрением современных методов комплексной обработки гетерогенной информации, использующих разрабатываемую интеллектуальную гибридную модель, позволило на новом уровне реализовать малолюдный режим работы. Это достигнуто путем выбора на шкалах измеряемых диагностических параметров таких диапазонов значений, соответствующих верхним уровням тревог («Тревога 2»), при которых показатели подтверждаемости равны 100%, и дополнительного подтверждения человеком наличия неисправности не требуется.

На основе разработанной гибридной модели базируется интеллектуальная система прогнозирования технического состояния подвижного состава и объектов инфраструктуры, которая позволяет на основе комплексных данных диагностики выявлять предотказные состояния единиц подвижного состава, определять категориальную вероятность их схода, а также оценивать степень их негативного влияния на железнодорожную инфраструктуру.

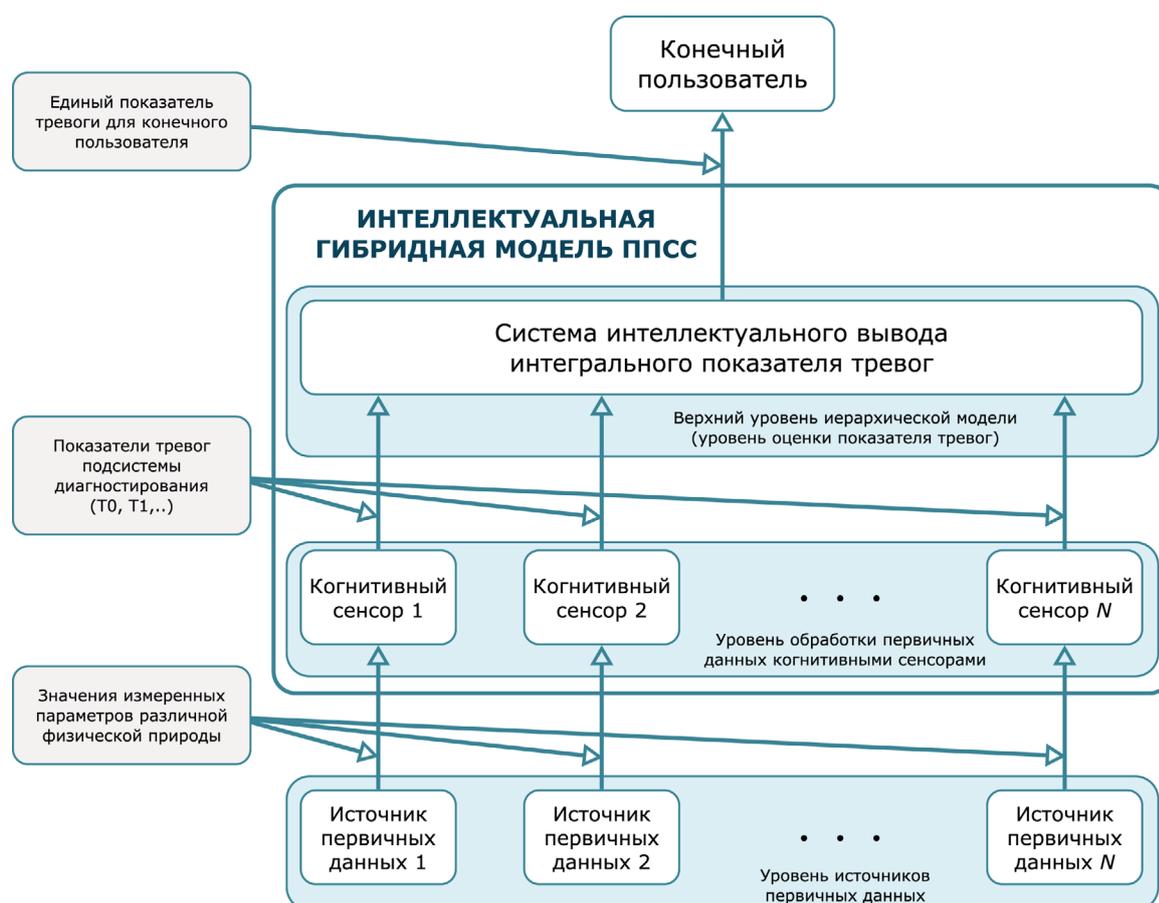


Рис. 1 – Структурная схема иерархической интеллектуальной среды

3. Интегрированный пост автоматизированного приема и обработки подвижного состава на сортировочных станциях (ППСС)

Комплекс ППСС представляет собой первую в практике РЖД комплексную диагностическую систему, которая была не только реализована, но и успешно внедрена (тиражирована) на сети железных дорог.

Его ключевым преимуществом является возможность проведения единого, совмещенного технического и коммерческого осмотра подвижного состава непосредственно в парке приема. Это достигается за счет глубокой автоматизации традиционных технологических процессов [12-14].

Функциональность ППСС построена на двух основаниях:

1. **Интеграция данных** от существующих диагностических систем (таких как КТСМ, КТИ, ПАК и др.).
2. **Внедрение нового, полностью автоматического функционала**, основанного на передовых технологиях:
 - **Машинное зрение** для визуального контроля: определение положения фрикционных клиньев, наличия и толщины тормозных колодок, распознавания инвентарных номеров, трафаретных надписей и знаков опасности.
 - **Тензометрия** для контроля нагрузок и целостности: измерение массы вагонов, выявление неравномерной загрузки, смещения центра тяжести и дефектов поверхности катания колес.

- **3D-сканирование** для геометрического анализа: обнаружение отрицательной динамики вагонов, дефектов кузова и нарушений габарита.
- **Дистанционный сбор данных** для мониторинга в реальном времени: автоматическое считывание информации с датчиков контроля состояния, установленных непосредственно на подвижном составе.

Таким образом, ППСС формирует целостную цифровую картину состояния каждого вагона, объединяя как унаследованные, так и принципиально новые источники диагностической информации. Визуальная организация измерительного участка комплекса показана на рисунке 2.



Рис. 2 – Измерительный участок комплекса ППСС

Структурная схема ППСС представлена на рисунке 3.

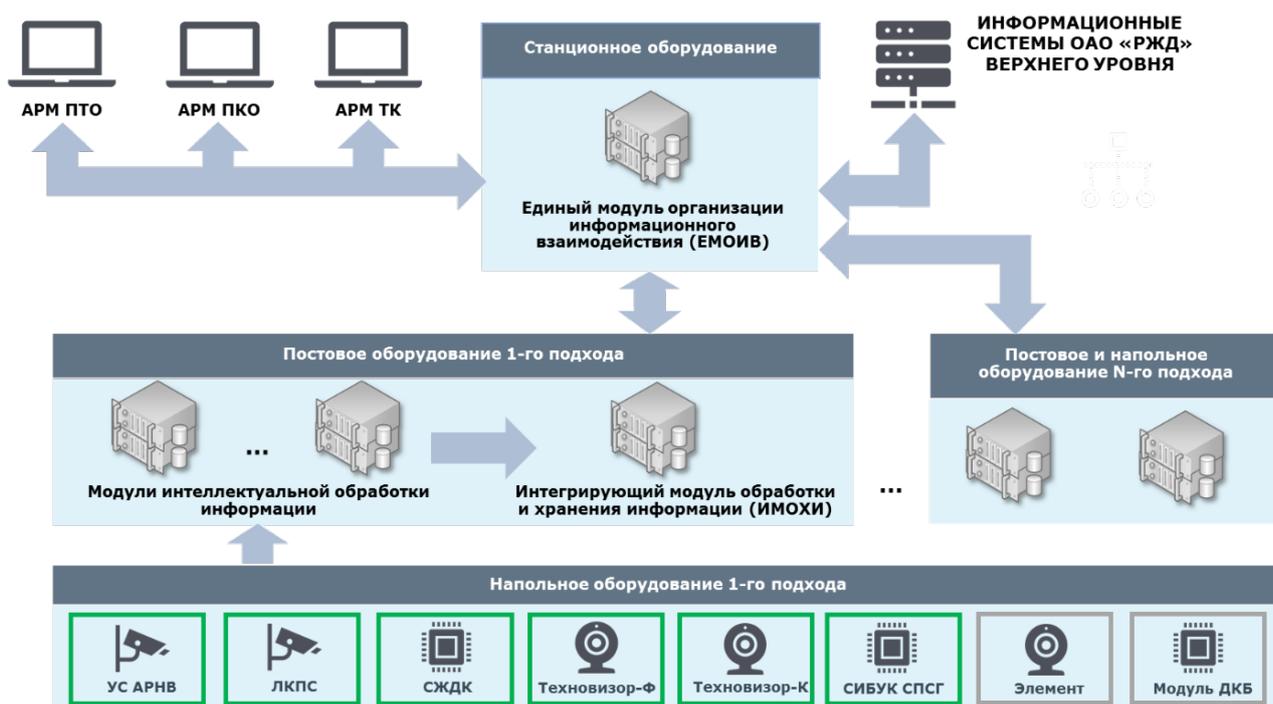


Рис. 3 – Структурная схема ППСС

Ключевым компонентом ППСС является единый модуль организации информационного взаимодействия (ЕМОИВ), который обеспечивает координацию работы всех модулей комплекса, автоматизацию процессов диагностирования и прогнозирования состояния подвижного состава. Корректная интерпретация результатов технического и коммерческого осмотра вагонов и грузов основывается на комплексировании модулем информации, поступающей от разнородных источников диагностических данных. Сформированные диагностические признаки передаются модулем в автоматизированные системы вагонного хозяйства в части технического обслуживания, хозяйства грузовой и коммерческой работы в части коммерческого осмотра, и информационно-управляющие системы в части управления процессами перевозок.

Особое внимание АО «НИИАС» уделяется важности метрологического обеспечения подсистем ППСС. В составе подсистем ППСС применены следующие типы средств измерения:

1. Модули, взвешивающие СЖДК.ВМ. Являются основой для реализации функционала подсистемы контроля веса и вертикальных динамических нагрузок (СЖДК). В СЖДК реализован принцип поколесного взвешивания единиц подвижного состава, что делает возможными как измерение веса, так и контроль неравномерности погрузки и смещения груза в пути следования. На СЖДК.ВМ получено свидетельство об утверждении типа средств измерения с погрешностью измерения веса от 0,2% до 1% в зависимости от скорости в диапазоне скоростей до 90 км/ч.
2. Модули фотограмметрических измерений линейных размеров «Техновизор». Впервые в мировой практике реализовано бесконтактное оптическое измерение линейных размеров элементов грузового подвижного состава. Зарегистрирован тип средств измерений с пределами допускаемой абсолютной погрешности измерений линейных размеров до ± 1 мм.
3. Модули лазерного измерения отрицательной динамики и габарита подвижного состава в составе системы лазерного контроля подвижного состава (ЛКПС). Важнейшим результатом, позволяющим в автоматическом режиме производить измерение габаритов и параметров отрицательной динамики грузовых вагонов в составе движущегося поезда стало утверждение в качестве типа средства измерения метрологического модуля ЛКПС.

4. Развитие функциональных возможностей ППСС

Модульная архитектура ППСС, представленная на рисунке 3, позволяет наращивать набор автоматически диагностируемых параметров с учетом актуального уровня развития программно-технических средств и технологий. Основными новыми модулями комплекса ППСС, расширяющими его функциональные возможности являются:

- система акустического контроля буксовых узлов модернизированная (ПАК-М);
- система контроля сохранности элементов подвижного состава (Элемент).

4.1 Система акустического контроля буксовых узлов модернизированная (ПАК-М)

В начале второго десятилетия нашего века на сети дорог ОАО «РЖД» впервые была внедрена разработанная АО «НИИАС» система контроля буксовых узлов Пост акустического контроля (ПАК). Системы ПАК достаточно эффективно эксплуатировались на сети железных дорог ОАО «РЖД» и за этот период выявили тысячи неисправных буксовых узлов. Вместе с тем, к концу второго десятилетия возникла острая необходимость в их серьезной модернизации.

В ходе инициативной разработки, начатой в 2019 году, специалистами АО «НИИАС» была проведена глубокая модернизация поста акустического контроля. Фактически, была создана новая система, получившая обозначение ПАК-М [15].

Модернизация затронула как аппаратную часть ПАК, так и программное обеспечение. На рисунке 4 представлен общий вид измерительного участка ПАК-М с установленным напольным оборудованием системы.



Рис. 4 – Общий вид измерительного участка ПАК-М

Система построена полностью на отечественных компонентах и позволяет выявлять неисправности как обычных роликовых, так и кассетных подшипников. Программный модуль учета пространственно-частотных характеристик электро-акустического тракта позволяет обеспечить единство измерений акустических сигналов буксовых узлов разными установками ПАК-М и реализовать контроль развития неисправностей.

Это открывает путь к развитию предиктивной аналитики состояния буксовых узлов по их шумовым сигналам, и, в перспективе, к снижению числа отцепок грузовых вагонов в пределах гарантийных плеч по показаниям аппаратуры типа КТСМ.

В составе ПО используются алгоритмы машинного обучения. Все это позволяет без особых доработок расширять функционал при необходимости диагностирования новых типов буксовых узлов.

Процесс развития дефектов буксовых подшипников иллюстрирует рисунок 5, на котором приведены типовые тренды технического состояния буксового подшипника и стоимости его технического обслуживания.

Этапы 2-3 имеют достаточно большую продолжительность, соответствующую нескольким тысячам километров пробега. Обнаружение дефектов на этих этапах и использование предиктивного трендового анализа обеспечивает организацию планирования технического обслуживания по фактическому и прогнозируемому состоянию. Обязательным условием здесь является многократный проход диагностируемых буксовых узлов через системы ПАК-М.

Наиболее коротким этапом развития дефектов буксовых узлов является этап 5, продолжительность которого обеспечивает пробеги не более сотен километров. Выявленные на этом этапе дефекты приводят к немедленным отцепам, что является одним из факторов высокой стоимости проводимых ТО. При этом несвоевременное обнаружение дефектов на данном этапе может приводить к фатальным последствиям, вследствие чего основным временным интервалом выявления дефектов буксовых узлов должны являться этапы 2-4.

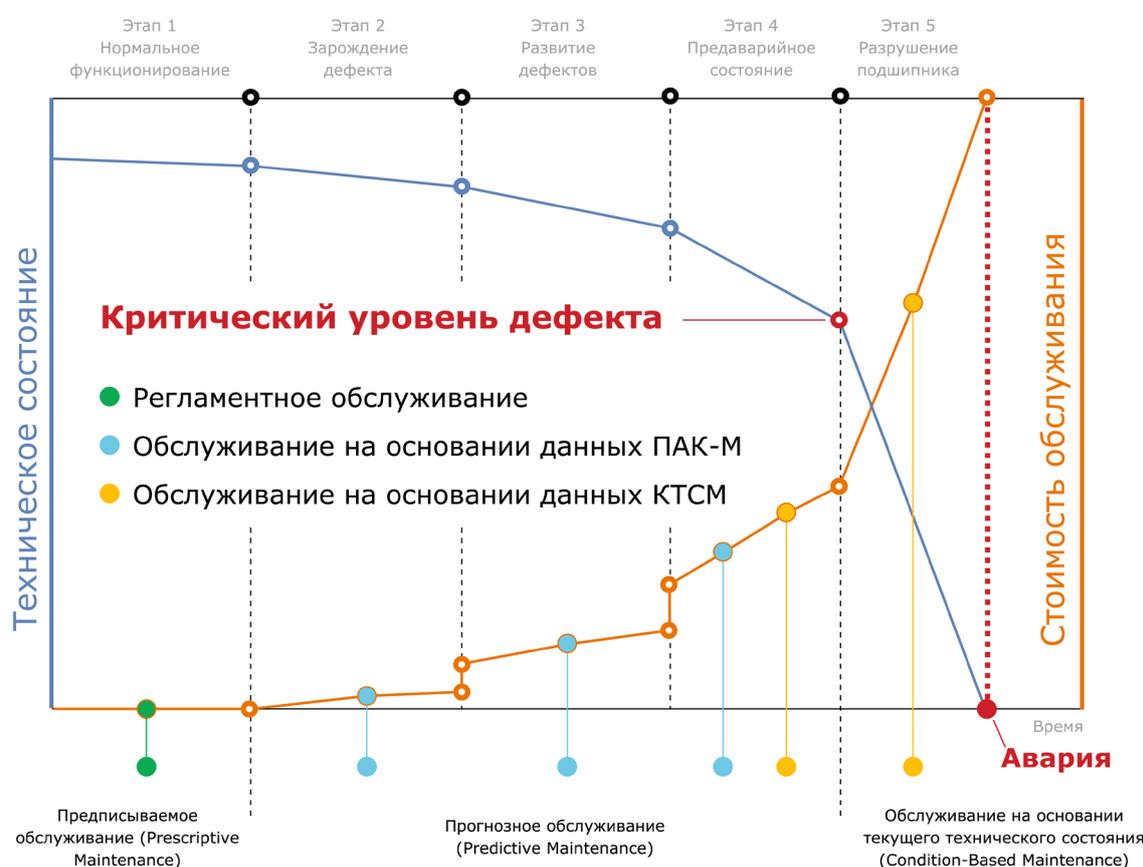


Рис. 5 – Этапы развития дефектов буксовых подшипниковых узлов и стоимость технического обслуживания

С учетом вышесказанного внедрение ПАК-М на железнодорожной сети позволяет:

- сократить количество unplanned остановок поездов;
- снизить время на обслуживание технических средств;
- рационально планировать работы по устранению неисправностей с учетом возможностей ремонтных предприятий за счет выявления ранней стадии развития и прогнозирования отказа;
- сократить затраты на заводской ремонт за счет раннего выявления дефекта.

ПАК-М размещаются в стратегически важных по интенсивности движения пунктах на сети дорог. Это позволяет выявлять дефекты подшипников буксовых узлов на ранних стадиях развития в зоне оборота грузовых вагонов до нескольких тысяч километров, отслеживать тренды развития неисправностей. С учетом этого, появляется перспектива существенного снижения количества внеплановых остановок поездов по тревожным показаниям аппаратуры типа КТСМ.

Модульные аппаратно-программные решения, применяемые в системе ПАК-М, позволяют легко интегрировать ее в состав комплекса ППСС.

4.2 Система контроля сохранности элементов подвижного состава «Элемент»

Важной и актуальной проблемой, приносящей большие финансовые потери и непосредственно влияющей на безопасность движения, является разоборудование грузовых вагонов.

Система контроля сохранности элементов подвижного состава «Элемент» [16] позволяет автоматизировать процесс контроля наличия важнейших узлов тормозного оборудования грузовых вагонов с выявлением отсутствующих деталей. Создание системы позволило выявлять в автоматическом режиме отсутствие таких элементов, как авторежим и авторегулятор, а также контролировать в автоматизированном режиме сохранность прочих узлов тормозного оборудования вагонов.

Работа системы основана на технологии машинного зрения, позволяющей формировать и обрабатывать детализированные изображения компонентов единиц подвижного состава при технологических скоростях движения. Высокая достоверность автоматического анализа состояния объектов подвагонного пространства обеспечивается применением нейронных сетей.

В системе Элемент использован метрологический модуль «Техновизор». Это позволило впервые производить на движущихся грузовых вагонах измерение фотограмметрическим методом таких важных параметров регулировки тормозной рычажной передачи, как А-большое и а-малое.

Регистрирующее оборудование системы «Элемент» представлено на рисунке 6.



Рис. 6 – Регистрирующее оборудование системы «Элемент»

На рисунке 7 представлен информационно-диагностический интерфейс системы «Элемент» при работе в составе ППСС.

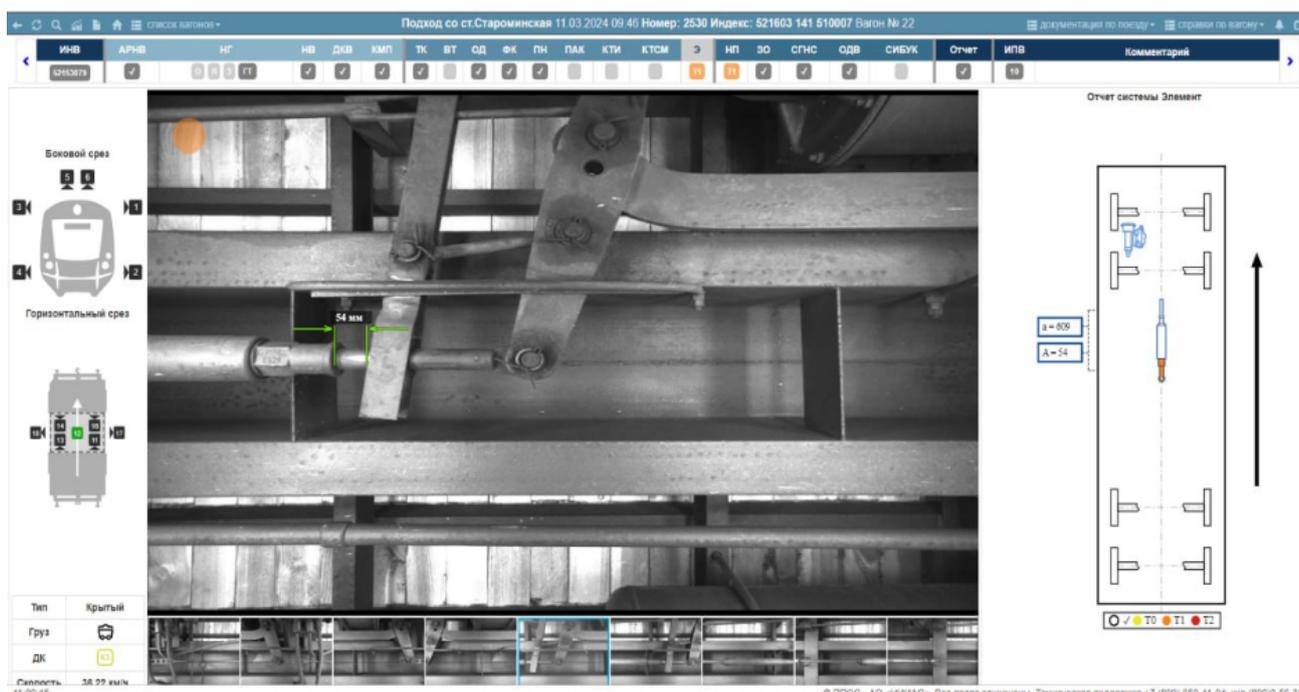


Рис. 7 – Информационно-диагностический интерфейс системы «Элемент» при работе в составе ППСС

В целях предотвращения загрязнения смотровых стекол камер системы АО «НИИАС» разработана и запатентована подсистема «воздушного лезвия» [17]. Уникальность технологии заключается в формировании мощного направленного воздушного потока, препятствующего попаданию пыли, атмосферных осадков и капель технологических жидкостей на смотровые стекла камер во время движения поезда.

В настоящее время в рамках реализации проекта «Цифровая железнодорожная станция» системой «Элемент» дооснащены пять комплексов ППСС на подходах к станции Челябинск-Главный Южно-Уральской железной дороги. По результатам эксплуатации системы «Элемент» по данным с точек контроля на подходах к станции Челябинск-Главный в среднем за месяц выявляется около 60 случаев разоборудования вагонов.

4.3 Реализация подхода к приоритетной браковке подвижного состава на основе дополнительного критерия безопасности

Дальнейшим развитием принципа комплексирования диагностических признаков, реализованного в ППСС, стал предложенный АО «НИИАС» подход приоритетной браковки подвижного состава, находящегося в наихудшем состоянии, на основе дополнительного критерия безопасности (ДКБ).

В рамках реализации инвестиционного проекта «Цифровая железнодорожная станция» на ст. Челябинск-Главный АО «НИИАС» ведутся работы по развитию функциональных возможностей ППСС в части автоматического выявления вагонов, находящихся в наихудшем техническом состоянии.

При этом реализуются мероприятия по разработке и внедрению модуля формирования критерия безусловной отцепки вагонов в текущий отцепочный ремонт (далее Модуль ДКБ), с внедрением опытных образцов на ст. Входная Западно-Сибирской железной дороги и ст. Челябинск-Главный Южно-Уральской железной дороги.

Модуль ДКБ позволяет минимизировать степень негативного влияния человеческого фактора на процесс принятия решения о браковке за счет внедрения комплексного организационно-технологического подхода к браковке вагонов с использованием данных от ППСС, а также от внешних систем вагонной диагностики (КТИ, КТСМ, ПАК/ПАК-М).

Указанный подход характеризует возможность постановки вагонов в рейс, в зависимости от результатов комплексного анализа обнаруженных неисправностей и прогнозирования динамики ухудшения состояния вагона в пути следования.

В основе подхода лежит принцип использования части ремонтных ресурсов станции на безусловную браковку неисправных вагонов с высокой вероятностью негативного влияния на безопасность перевозочного процесса.

В соответствии с целевой схемой организации процесса автоматической браковки грузовых вагонов, находящихся в наихудшем техническом состоянии, ППСС, оснащенный модулем ДКБ, формирует и передает в ЕК АСУВ тревожные показания по функции «ДКБ», на основании которых ЕК АСУВ автоматически принимает решение о формировании уведомления ВУ-23 ВЦ.

При этом обеспечивается прозрачность оценки технического состояния подвижного состава, значительно снижается негативное влияние человеческого фактора на процесс принятия решения о браковке вагонов, находящихся в наихудшем техническом состоянии. Обеспечивается вывод из эксплуатации вагонов, негативно влияющих на инфраструктуру, так же снижается нагрузка на процесс организации движения по пути следования поезда в части маневровой работы на промежуточных станциях.

В соответствии с результатами имитационного моделирования работы функции «ДКБ» на ст. Челябинск-Главный произведена оценка степени влияния неисправностей, выявленных ППСС, эксплуатируемыми на указанных станциях, на формирование тревожных показаний по функции «ДКБ».

Наибольшее количество вагонов с тревожным показанием по «ДКБ» имеют неисправности, связанные с износом фрикционных клиньев, наличием дефектов поверхности катания колесных пар и шумом буксовых узлов.

При этом, наибольшее влияние на формирование тревожного показания по функции «ДКБ» оказывают неисправности, связанные с износом фрикционного клина (52%) и шумом буксовых узлов (26%).

Специалистами АО «НИИАС» проведено моделирование динамики изменения технического состояния вагонного парка при внедрении ДКБ на ст. Челябинск-Главный.

На диаграмме, представленной на рисунке 8, представлена прогнозируемая динамика изменения структуры тревожных показаний, сформированных ППСС.

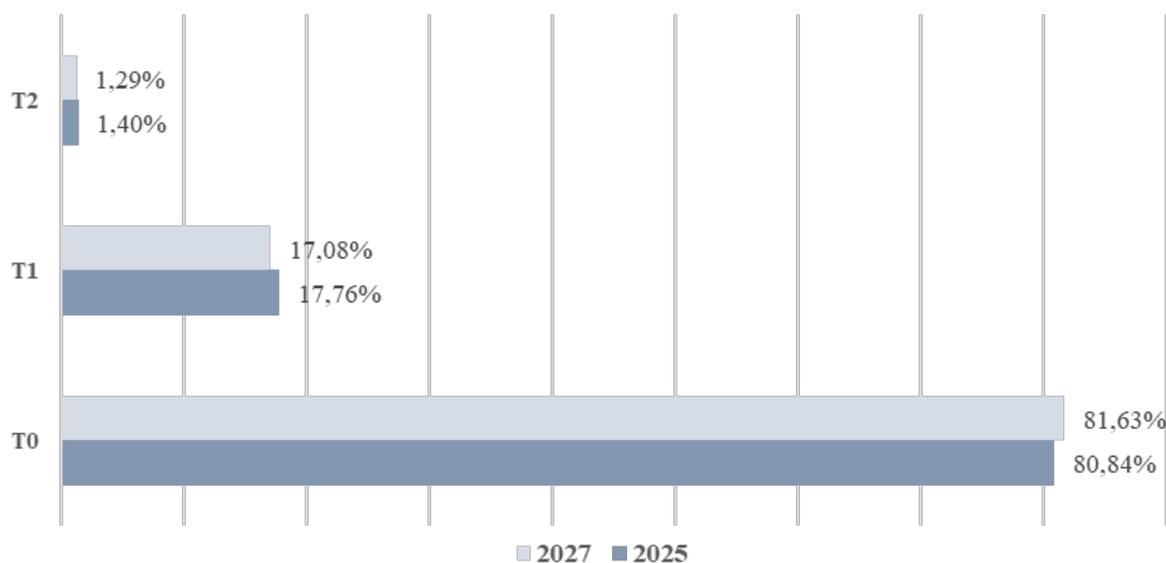


Рис. 8 – Прогнозируемая динамика изменения структуры тревожных показаний, сформированных ППСС.

Указанная диаграмма свидетельствует о снижении доли тревожных показаний аварийного и предаварийного уровня T2 и T1 и увеличении доли тревожных показаний диагностического уровня T0 в общем количестве тревог ППСС. То есть показатель технического состояния грузового подвижного состава, курсирующего по путям ОАО «РЖД» по результатам моделирования улучшится.

Первые результаты практического применения данного подхода на станциях Челябинск-Главный ЮУЖД и Входная ЗСЖД позволяет судить о высокой эффективности предложенного подхода. Автоматическое выявление грузовых вагонов, находящихся в

наихудшем техническом состоянии, производилось согласно утвержденной методике формирования безусловной отцепки вагонов в ТОР. Так, только за месяц (с 15.09.25 по 14.10.25) опытной эксплуатации Модуля ДКБ на станции Челябинск-Главный были отцеплены 56 забракованных вагонов. Подтверждаемость показаний составила 100%.

Очевидно, что существенное влияние на состояние вагонного парка Модуль ДКБ окажет только в случае его внедрения на всей сети. При этом степень его влияния может быть точно определена на основе статистических данных, которые появятся после ввода Модуля ДКБ в эксплуатацию.

4.4 Интеграция ППСС в станционные информационно-управляющие комплексы

В рамках решения задачи цифровизации сортировочного комплекса железнодорожной станции специалистами АО «НИИАС» разработана схема информационного взаимодействия модулей станции (рис. 10), в которой ППСС выступает основным источником данных, позволяющих повысить перерабатывающую способность автоматизированных сортировочных горок. Пилотным объектом реализации данного подхода стала ст. Челябинск-Главный Южно-Уральской железной дороги. При этом комплекс ППСС формирует следующие дополнительные информационные потоки:

1. Передача данных о технических характеристиках вагонов (тип, габарит, парусность, физический вес и др.) и о состоянии их узлов (дефекты поверхности катания колес, износ тормозных колодок и др.), влияющих на ходовые свойства отцепа, в управляющую систему «Комплексная система автоматизации управления сортировочным процессом (КСАУ СП)» для учета в алгоритмах интервального и прицельного регулирования скорости движения отцепов.
2. Передача в АСУ СТ информации для автоматического предзаполнения уведомления формы ВУ-23 по факту обнаруженных технических неисправностей в диагностируемых вагонах.
3. Передача данных о фактическом натурном листе поезда в систему контроля и подготовки информации о перемещениях вагонов и локомотивов на станции в реальном времени (СКПИ ПВЛ РВ) для повышения качества распознавания подвижных единиц.

Дополнительный информационный поток 1 позволяет учесть факторы, оказывающие влияние на динамику движения отцепов и повысить степень адаптивности управления процессом роспуска.

Так, например, управление роспуском с учетом силы ветра и аэродинамического сопротивления вагона производится в КСАУ СП на базе получаемого из ППСС набора значений площади проекций вагона, вычисленных с шагом 5 градусов по 3D-модели вагона и груза, построенной системой ЛКПС (рисунок 9).

Расчет силы, действующей на вагон, производится в КСАУ СП по формуле:

$$F_d = \frac{1}{2} \cdot \rho \cdot A \cdot C_d \cdot v^2 ,$$

где, ρ – плотность воздуха, A – общая площадь объекта по направлению потока воздуха, C_d – безразмерный коэффициент сопротивления, v – скорость объекта относительно среды.

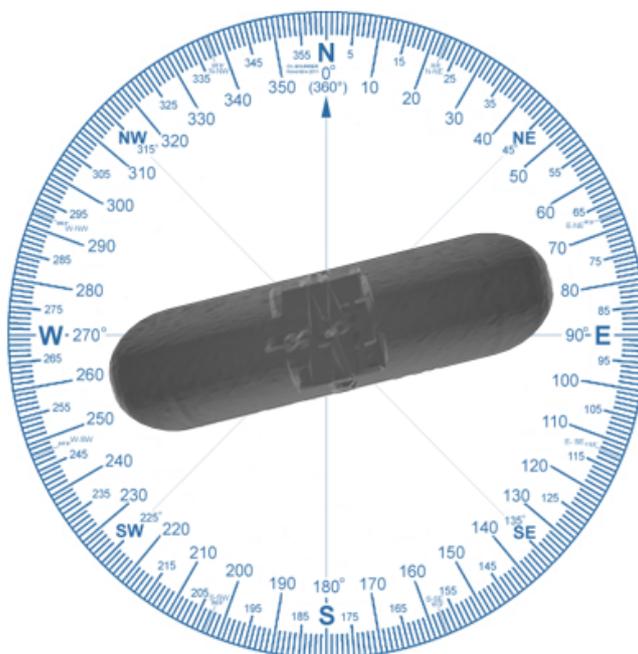


Рис. 9 – Определение набора значений площади проекций вагона, полученных из 3D-модели вагона и груза, построенной системой ЛКПС

Основными эффектами интеграции ППСС с информационно-управляющими системами и комплексами сортировочной станции являются:

1. Увеличение перерабатывающей способности сортировочной горки.
2. Автоматизации процессов браковки вагонов и формирования сортировочного листа.
3. Повышение достоверности коммерческого осмотра подвижного состава во взаимодействии с Подсистемой интеллектуального коммерческого осмотра поездов и вагонов в составе Автоматизированной системы оперативного контроля и анализа качества коммерческой работы и безопасности грузовых перевозок (АСКМ ИКО).
4. Снижение числа внеплановых отцепок подвижного состава за счет реализации ППСС алгоритмов предиктивной аналитики состояния подвижного состава и груза.
5. Повышение скорости обработки вагонопотока и эффективности планирования работы полигонов.

ППСС послужил катализатором для развития новых подходов к созданию диагностических средств и внедрению диагностических комплексов для автоматизации технологических процессов диагностики на различных объектах железнодорожного транспорта и в различных хозяйствах.

Так, в ходе работы над проектом «Цифровая железнодорожная станция» (ЦЖС), реализующем концепцию создания станции-автомата, потребовалось организовать функционал автоматизированной комплексной системы контроля магистральных локомотивов в движении на стационарных постах на подходах к станции Челябинск-Главный. Общие принципы построения системы и гибридная модель комплексирования диагностических признаков, реализованные в ППСС, позволили создать модульную Автоматизированную систему контроля локомотивов (АСКОЛ), реализующую функционал контроля токоприемников локомотивов, контроля сдвига бандажей колес, наличия трещин и обратного прогиба рессор локомотивов, диагностирования тормозных колодок, контроля дефектов поверхности катания и геометрии колес, выявления дефектов кузова, распознавания инвентарных номеров локомотивов.

В настоящее время система АСКОЛ смонтирована на подходе к станции Челябинск-Главный, ее ввод в эксплуатацию позволит, совместно с ППСС, решить задачу автоматизации диагностирования всех единиц подвижного состава в поездах, прибывающих на сортировочную станцию.

Еще одной важной задачей, которую требуется решать при переходе к технологии автоматизированной обработки поездов является задача контроля технического состояния грузовых вагонов в пунктах технической передачи вагонов с путей необщего на пути общего пользования. Эта задача решается АО «НИИАС» путем разработки и внедрения системы контроля грузовых вагонов в пунктах технической передачи (КПТП). В настоящий момент опытный образец системы готовится к вводу в опытную эксплуатацию на ст. Дубровка ЮУЖД.

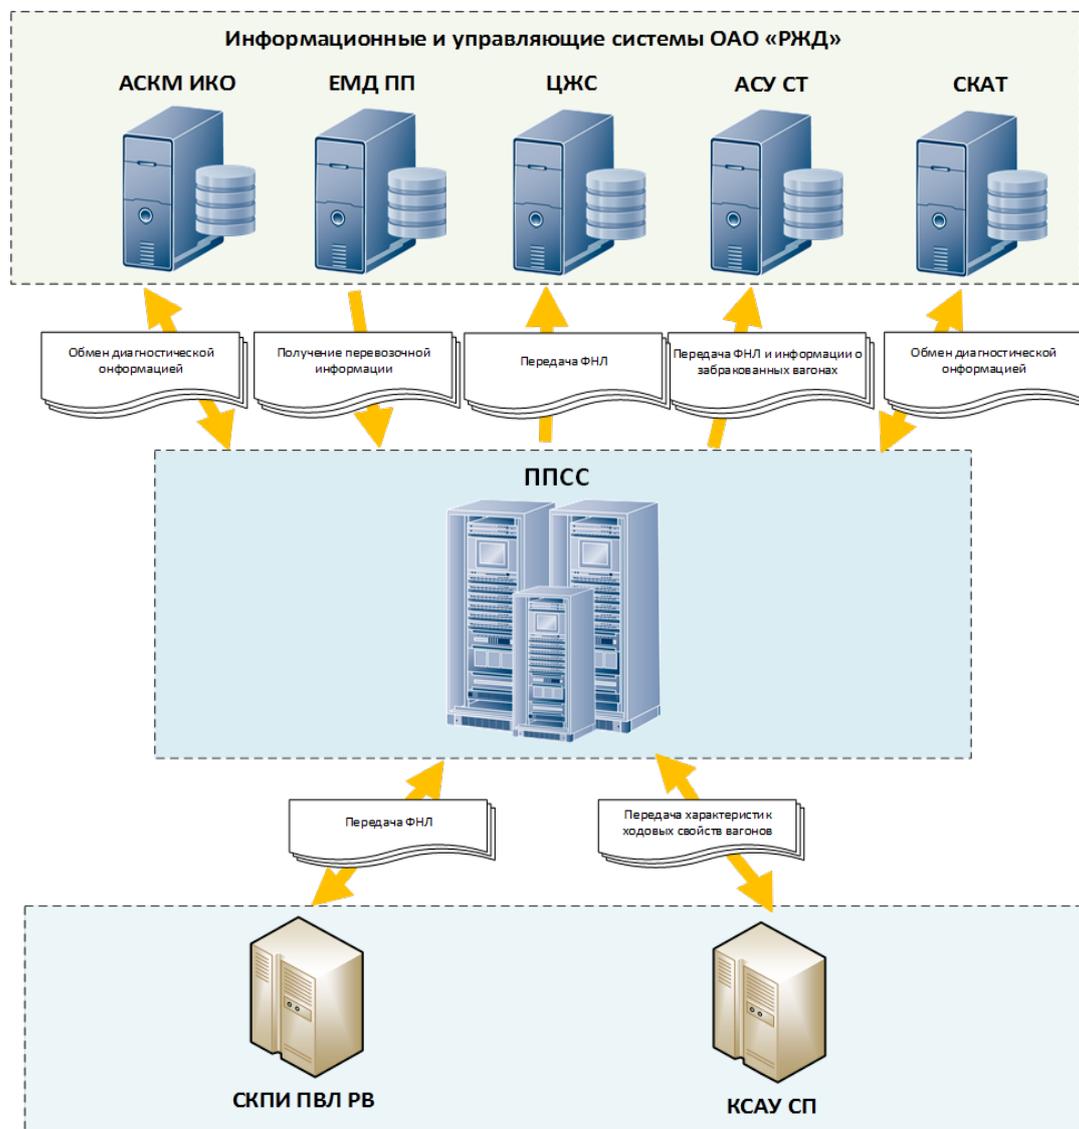


Рис. 10 – Схема информационного взаимодействия комплекса ППСС со смежными системами

Принцип контроля состояния вагонов, реализуемый в данной системе, основан как на контроле технического состояния вагонов при приеме с путей промышленных предприятий на пути общего пользования, так и на сравнении с их состоянием при передаче на пути необщего пользования. С этой целью измерительные участки системы КПТП организуются как перед входными, так и после выходных путей промышленных предприятий. Такой подход позволяет не только выявлять поврежденные вагоны, возвращаемые с территории промышленных предприятий на пути общего пользования, но и определять фактическое место повреждения.

В КПТП реализован функционал диагностирования грузовых вагонов по более, чем 57 диагностическим признакам (включая диагностирование зазоров в скользунах, выявление дефектов поверхности катания колесных дисков, контроль геометрии кузова и т.д.), что в два раза превышает объем диагностических параметров, проверяемых в ППСС.

Еще одним важным звеном в реализации задачи автоматизации процессов диагностирования подвижного состава является автоматизация приемки грузовых вагонов в эксплуатацию после плановых видов ремонта. Данный функционал решает разрабатываемая в настоящее время система контроля грузовых вагонов при выходе из ремонта (КПВР).

В рамках этого технологического процесса дополнительно приходится решать задачи контроля несоответствия комплектации вагонов данным информационных систем с обнаружением и распознаванием клеев на деталях грузовых вагонов, контроля состояния и измерения параметров компонентов вагона, находящихся в труднодоступных местах, контроля ходовой части, автосцепки и поглощающего аппарата, включая контроль соответствия сроков службы компонентов, надписей на вагоне и т.д.

4.5 Роботизация процессов диагностирования подвижного состава

Проведенный анализ показывает, что диагностирование ряда параметров узлов грузового вагона в движении с помощью методов, используемых в системах ППСС и КПТП невозможно или крайне затруднено.

Современный этап развития промышленности и транспорта характеризуется бурным развитием роботизации технологических процессов на базе машинного зрения и искусственного интеллекта. Безусловно, данное направление является крайне перспективным для использования при решении задачи перехода к безлюдным технологиям диагностирования железнодорожного подвижного состава.

В этой связи в ходе работы над проектом КПВР специалистами АО «НИИАС» активно прорабатывается использование для решения данной задачи биоморфных роботов, способных производить контроль и измерение требуемых параметров на неподвижных вагонах.

Робот-собака или робот на гусеничной платформе, оснащенные манипуляторами с установленными на них необходимыми регистрирующими и измерительными средствами, способны приблизиться на необходимое расстояние к объекту обследования, оптимально позиционироваться относительно него с помощью встроенной системы машинного зрения и произвести необходимые измерения (рисунок 11).



Рис. 11 – Исследовательские испытания экспериментального образца биоморфного робота, реализующего задачу обследования узлов грузового вагона

Развитие данного направления открывает широкие возможности для реализации технологий, основанных на скоординированных действиях нескольких функционально дополняющих друг друга роботов и роевых алгоритмах управления группами роботов.

Подходы, реализованные при разработке и внедрении таких комплексных диагностических систем, как ППСС, АСКОЛ, КПТП, КПВР, позволяют организовать взаимодействие этих систем между собой, а также с информационными системами АО «РЖД» верхнего уровня (в том числе ЕК АСУ В, ЕК АСУ Т, АСКМ ИКО, СКАТ и т.д.) и ремонтными предприятиями вагонного и локомотивного комплекса как на станционном, так и на дорожном уровне, и открывают путь к созданию станционных или распределенных региональных диагностических кластеров (хабов), основанных на автоматизации и роботизации технологических процессов диагностирования подвижного состава. Возможная схема взаимодействия объектов диагностического кластера представлена на рисунке 12.

Диагностические кластеры при данном подходе являются «входными воротами» и источником оперативных, полных и достоверных данных для управляющих станционных

комплексов Цифровая железнодорожная станция (ЦЖС), а в дальнейшем и полигонных комплексов управления, и фундаментом для трансформации технологии работы крупных железнодорожных станций. Они определяют дальнейший порядок переработки составов на сортировочной станции, исключают из переработки «больные» вагоны, оптимизируют процесс ремонта неисправных вагонов с учетом свободных ресурсов ремонтных предприятий и наличия запчастей, обеспечивают информацией робототехнические комплексы ЦЖС и системы горочной автоматики.

Информация, аккумулируемая в информационной системе регионального диагностического центра, позволит осуществлять консолидацию и нормализацию разнородных данных, а также выявлять закономерности между диагностическими данными, формируемыми различными диагностическими средствами и системами, и показателями эффективности перевозочного процесса на сети ОАО «РЖД».

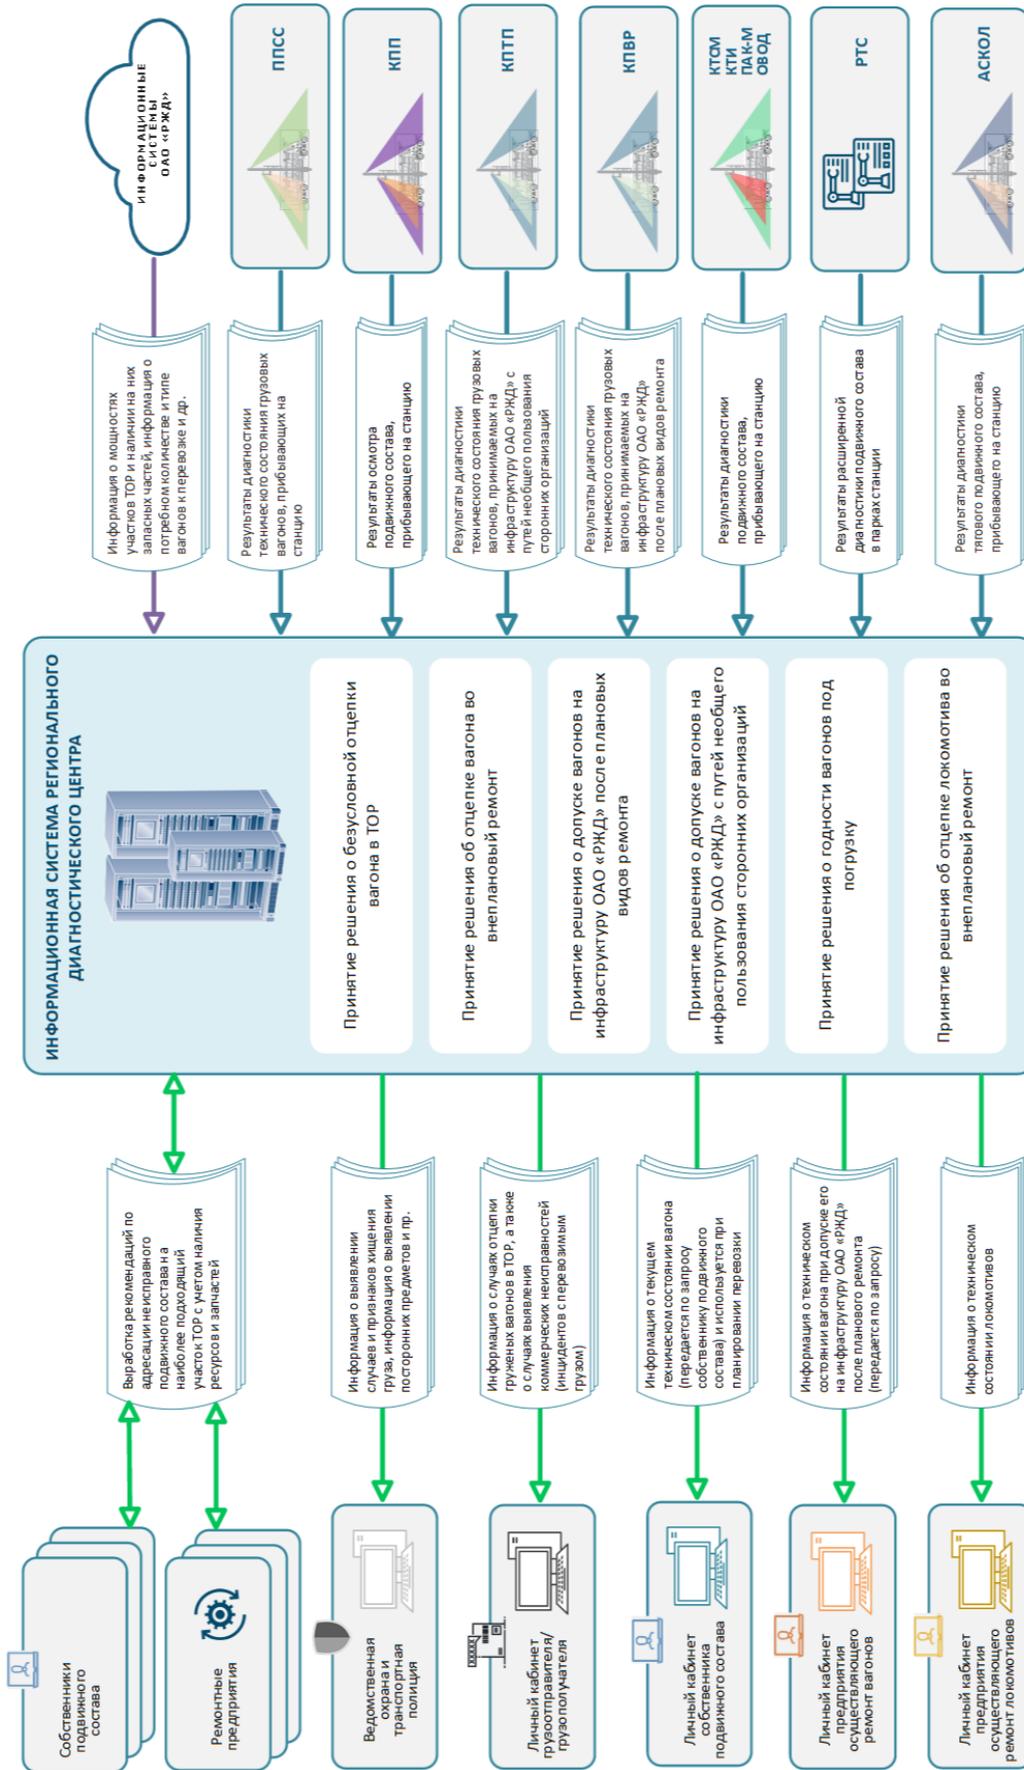


Рис. 12 – Схема взаимодействия объектов диагностического кластера

Заключение

В статье представлен комплексный подход к процессу диагностирования подвижного состава. Эксплуатация ППСС и внедрение комплексов и систем, являющихся дальнейшим его развитием, порождают дополнительные синергетические эффекты, способствующие повышению качества работы диагностической инфраструктуры и смежных систем.

Представлены примеры новых программно-технических средств, которые интегрируются в состав диагностических комплексов и позволяют расширить перечень диагностируемых параметров, повысить степень автоматизации технологических процессов, сократить издержки и время доставки грузов, перейти к предиктивной аналитике процессов.

Описаны подходы, позволяющие автоматизировать и роботизировать процессы диагностирования и браковки подвижного состава, объединять диагностические системы в диагностические кластеры и интегрировать их в перспективные станционные и полигонные цифровые информационно-управляющие комплексы.

Таблица 1 систематизирует ключевые аспекты зарубежных решений и разработок АО «НИИАС» в области диагностики подвижного состава.

На основе такого сравнительного анализа зарубежных решений и разработок АО «НИИАС» можно сделать несколько фундаментальных выводов.

Прежде всего, наблюдается значительная конвергенция технологических траекторий. АО «НИИАС» развивается в полном соответствии с общемировыми трендами, последовательно проходя путь от автоматизации отдельных процессов к созданию интегрированных интеллектуальных систем. ППСС в этом смысле воплощает в себе ключевые принципы современной диагностики: модульность, мультисенсорность и глубокую автоматизацию осмотра на ходу поезда.

При этом АО «НИИАС» демонстрирует ярко выраженную уникальность в области методологии обработки информации. Если мировой тренд сосредоточен на применении стандартных алгоритмов машинного обучения, то российский институт развивает собственную глубокую компетенцию в создании гибридных моделей анализа данных. Использование когнитивных сенсоров, гранулярных логических семантик и прагматики для комплексирования разнородных диагностических признаков представляет собой серьезное конкурентное преимущество и научный задел.

Таблица 1

**Зарубежные решения и разработки АО «НИИАС»
в области диагностики подвижного состава**

Аспект	Зарубежные решения (мировые тренды)	Разработки АО «НИИАС» (на примере ППСС и др.)
Эволюция	От одиночных датчиков → стационарные порталы → бортовые IRV-системы → роботизированные платформы.	ПАК → комплекс ППСС → системы АСКОЛ, КППТ, КПВР → роботизированные хабы.
Архитектура систем	Модульные путевые порталы, бортовые Instrumented Revenue Vehicles (IRV), мобильные роботы.	Модульная архитектура ППСС с единым модулем организации информационного взаимодействия (ЕМОИВ).
Ключевые технологии	Машинное зрение, лазерное сканирование, тепловизионный контроль, акустическая эмиссия, вибродиагностика, IoT, AI/ML.	Машинное зрение, лазерное сканирование (ЛКПС), тензометрия (СЖДК), акустический контроль (ПАК-М), 3D-сканирование, гибридная модель обработки данных.

Аспект	Зарубежные решения (мировые тренды)	Разработки АО «НИИАС» (на примере ППСС и др.)
Интеграция данных	Sensor fusion (ранняя, поздняя), облачные платформы, централизованные аналитические системы.	Гибридная модель комплексирования диагностических признаков с использованием гранулярных логических семантик и когнитивных сенсоров.
Предиктивная аналитика	Активное применение ML (CNN, RNN, Random Forest) для прогноза откзов, цифровые двойники.	Развитие предиктивной аналитики на основе трендов (ПАК-М), прогнозирование состояния на основе гибридной модели.
Автоматизация процессов	Автоматическая инспекция на ходу, системы типа PRISM (Китай), Automated System for Commercial Inspection.	Полная автоматизация технического и коммерческого осмотра в ППСС, интеграция со СКАТ и КСАУ СП.
Роботизация	Мобильные роботы-инспекторы для депо, дроны, автономные платформы (стадия пилотов и внедрения).	Экспериментальные биоморфные роботы для обследования неподвижных вагонов (КПВР), планы по созданию диагностических кластеров.
Метрологическое обеспечение	Соответствие международным стандартам (ISO, IEC, EN), сертификация по ASTM, квалификация персонала по ISO 9712.	Разработка и утверждение типов средств измерения (СЖДК.ВМ, «Техновизор», ЛКПС), патентование решений (воздушное лезвие).
Экономические модели	CAPEX/OPEX-модели, Monitoring-as-a-Service, партнёрства, ROI-ориентированный подход.	Внедрение в рамках инвестиционных проектов («Цифровая железная дорога», «Цифровая железнодорожная станция»), оценка экономического эффекта через снижение отцепок.
Региональные особенности	Европа: стандартизация (ERTMS, TSI), IRV. Сев. Америка: wayside detectors, акцент на грузовые перевозки. Азия: масштабное внедрение (PRISM в Китае), высокая автоматизация.	Создание комплексов под специфику сети РЖД, внедрение на ключевых станциях (Челябинск-Главный, Входная), развитие для сортировочных станций и пунктов передачи.
Уровень внедрения	От пилотных проектов (роботы) до массового внедрения (путевые порталы, IRV в ЕС и США).	Серийное внедрение ППСС, ПАК-М на сети РЖД, опытная эксплуатация, КПТП, модуля ДКБ; эксперименты с роботами.
Безопасность и регуляторика	Соответствие директивам ЕС (ERA), FRA (США), стандартам AAR, требованиям RAMS (IEC 62278).	Разработка дополнительного критерия безопасности (ДКБ) для приоритетной браковки, интеграция с системами безопасности РЖД.
Перспективы	Цифровые двойники, автономные роботизированные комплексы, прескриптивная аналитика, глобальные платформы данных.	Создание диагностических кластеров (хабов), интеграция всех систем (ППСС, АСКОЛ, КПТП, КПВР) в единую цифровую экосистему станции.

Эта работа направлена не просто на обнаружение дефектов, а на формирование целостной оценки состояния и прогноза его изменения, что соответствует высшему уровню развития диагностических систем – предиктивно-прескриптивному.

Важнейшим отличием является глубокая практико-ориентированность и системность подхода АО «НИИАС». Разработки института изначально встроены в технологические процессы ОАО «РЖД» и нацелены на решение конкретных производственных задач – от автоматизации приемки на сортировочных станциях до контроля сохранности оборудования и приоритетной браковки вагонов. Создаваемая экосистема (ППСС, АСКОЛ, КППП, КПВР) охватывает полный жизненный цикл взаимодействия с подвижным составом, что свидетельствует о стратегическом, а не точечном подходе к цифровизации. Высокая степень внедренческой готовности и тиражируемости решений на сети дорог подтверждает их эффективность и востребованность.

В то же время, как и в общемировой практике, направление роботизации физических процессов диагностики в АО «НИИАС» находится на стадии экспериментальной разработки. Работы над биоморфными роботами для обследования неподвижных вагонов соответствуют глобальному тренду, но пока отстают от уровня пилотных промышленных внедрений, наблюдаемых у некоторых зарубежных коллег. Это закономерно определяет данное направление как одно из ключевых для будущих исследований.

Резюмируя, можно сказать, что АО «НИИАС» не только успешно адаптирует глобальные технологические тренды к масштабам и специфике российской железнодорожной сети, но и ведет самостоятельную научно-техническую работу, создавая уникальные решения в области интеллектуального анализа данных и комплексной интеграции диагностики в управление перевозочным процессом. Это позволяет говорить о формировании собственного, конкурентоспособного технологического пути в области диагностики подвижного состава.

Список использованной литературы

1. Долгий А. И. Концептуальный подход к построению современной платформы управления перевозочным процессом в ОАО «РЖД» // Труды АО «НИИАС»: сб. ст. – М.: АО «НИИАС», 2021. – Т. 1, Вып. 11. – С. 9–31.
2. V. B. Degtyar, A. K. Domnin, A. A. Ermakov et al., *Automated System for Commercial Inspection of Trains and Carriages*. Pat. – (2016). [Online]. Available: <https://scispace.com/papers/automated-system-for-commercial-inspection-of-trains-and-3vp8x8t1lu>.
3. I. R. Buchin, A. A. Vasilkov, A. P. Noskov et al., *Integrated Station for Automated Reception and Diagnostics of Rolling Stock (PRISM)*. Pat. – (2020). [Online]. Available: <https://scispace.com/papers/integrated-station-for-automated-reception-and-diagnostics-4pdrxah5vq>.
4. S. Guo, S. Yin, and H. Xie, “A Distributed Measurement System to Detect Train Wheel Condition,” in *Proc. AINIT*, 2024. DOI: 10.1109/ainit61980.2024.10581416.
5. A. O. Kalabekov, O. A. Kalabekov, A. A. Nemtsev et al., *Automated System for Commercial Inspection of Trains and Cars with a Modular Architecture (ASKO PV 3.0)*. Pat. – (2020). [Online]. Available: <https://scispace.com/papers/automated-system-for-commercial-inspection-of-trains-and-4ki8mhs4my>.
6. M. Z. Shaikh, Z. Ahmed, B. S. Chowdhry et al., “State-of-the-Art Wayside Condition Monitoring Systems for Railway Wheels: A Comprehensive Review,” *IEEE Access*, vol. 11, pp. 13122–13155, 2023. DOI: 10.1109/ACCESS.2023.3240167.
7. G. M. Azanaw, “Optimizing Railway Safety and Efficiency: A Comprehensive Review on Advancements in Out-of-Round Wheel Detection Systems,” *Int. J. Inventive Eng. Sci.*, vol. 12, no. 3, pp. 1–15, 2025. DOI: 10.35940/ijies.a1324.12030325.
8. R. Ravitharan, “Safer Rail Operations: Reactive to Proactive Maintenance Using State-of-the-Art Automated In-service Vehicle-Track Condition Monitoring,” in *Proc. ICIRT*, 2018. DOI: 10.1109/ICIRT.2018.8641587.
9. S. Kolathayar, “Peer Review Report For: Digital Twins for Managing Railway Maintenance and Resilience [version 1; peer review: 2 approved],” *Open Res. Europe*, vol. 1, p. 91, 2021. [Online]. Available: <https://doi.org/10.21956/openreseurope.14885.r27389>.
10. E. Tutumluer, S. Nazarian, I. Al-Qadi, and I. Qamhia, Eds., *Advances in Transportation Geotechnics IV: Proc. 4th Int. Conf. Transp. Geotechnics*, vol. 1. Springer, 2022. DOI: 10.1007/978-3-030-77230-7.
11. J. Kim, C.-H. An, S. R. Lee, and J.-H. Han, “A Study on Necessity to Introduce Prognostic Maintenance of Rolling Stock,” in *Proc. Asia Pacific Conf. PHM Soc.*, 2017. [Online]. Available: <https://doi.org/10.36001/phmap.2017.v1i1.2062>.

12. Хатламаджиян А. Е., Лебедев А. И. Интегрированный пост автоматизированного приёма и диагностики подвижного состава на сортировочных станциях // Вагоны и вагонное хозяйство. – 2019. – № 2 (58). – С. 9–13.
 13. Долгий А. И., Хатламаджиян А. Е., Кудюкин В. В., Шаповалов В. В. Устройство определения параметров узлов подвижного состава: пат. на изобр. RU 2668774 С2; заявл. 16.12.2016; опубл. 02.10.2018. Бюл. № 28.
 14. Долгий А. И., Кудюкин В. В., Розенберг Е. Н., Розенберг И. Н., Хатламаджиян А. Е., Шаповалов В. В. Система технического и коммерческого контроля состояния поездов: пат. на изобр. RU 2728202 С1; заявл. 02.12.2019; опубл. 28.07.2020. Бюл. № 21.
 15. Гуров Ю. В., Долгий А. И., Куценко А. Н., Пулин А. В., Хатламаджиян А. Е., Шаповалов В. В. Способ акустического контроля состояния буксовых узлов движущегося поезда: пат. на изобр. RU 2781416 С1; заявл. 24.05.2022; опубл. 11.10.2022. Бюл. № 28.
 16. Андреев О. А., Долгий А. И., Пулин А. В., Слепых К. В., Хатламаджиян А. Е., Шаповалов В. В., Шутько А. Н. Система контроля сохранности элементов подвижного состава: пат. на изобр. RU 2811171 С1; заявл. 17.11.2023; опубл. 11.01.2024. Бюл. № 1.
 17. Андреев О. А., Долгий А. И., Пулин А. В., Хатламаджиян А. Е., Шаповалов В. В., Шутько А. Н. Система защиты бесконтактных датчиков технического контроля на железнодорожном пути: пат. на изобр. RU 2800881 С1; заявл. 11.04.2023; опубл. 31.07.2023. Бюл. № 22.
-

УДК 656.1:004.896

БЕЗОПАСНОСТЬ АВТОНОМНЫХ ТРАНСПОРТНЫХ СРЕДСТВ: КОМПЛЕКСНЫЙ АНАЛИЗ И СТРАТЕГИЧЕСКИЕ ПЕРСПЕКТИВЫ

Куверин Игорь Юрьевич, к.т.н., доцент СГТУ имени Гагарина Ю.А., Саратов, Россия, E-mail: igorkuv@mail.ru

Гусев Сергей Александрович, д.э.н., зав. кафедрой СГТУ имени Гагарина Ю.А., Саратов, Россия,

E-mail: o051nm@yandex.ru

Блинов Дмитрий Геннадьевич, аспирант СГТУ имени Гагарина Ю.А., Саратов, Россия,

E-mail: bdg@rusptk.com

АННОТАЦИЯ

В статье проводится комплексный анализ безопасности автономных транспортных средств как перспективного решения глобальной проблемы дорожно-транспортного травматизма. На основе актуальных данных за 2023-2025 годы из международных источников, проводится сравнительная оценка аварийности беспилотных и традиционных автомобилей. Подробно рассматривается технологический потенциал автономных систем для исключения человеческого фактора – основной причины ДТП. Исследуются ключевые барьеры массового внедрения: технические ограничения, проблемы кибербезопасности, правовая неопределенность и низкий уровень общественного доверия. В заключении формулируются стратегические направления для безопасной интеграции технологий, включая развитие нормативной базы, повышение прозрачности тестирования и совершенствование алгоритмов искусственного интеллекта.

Ключевые слова: беспилотные автомобили, интеллектуальный транспорт, безопасность дорожного движения, автономные транспортные средства, искусственный интеллект, общественное восприятие, нормативное регулирование.

SAFETY OF AUTONOMOUS VEHICLES: COMPREHENSIVE ANALYSIS AND STRATEGIC PERSPECTIVES

Igor Y. Kuverin, PhD, Associate Professor, Gagarin State Technical University, Saratov, Russia,

E-mail: igorkuv@mail.ru

Sergey A. Gusev, Doctor of Economics, Head of the Department of Gagarin State Technical University, Saratov, Russia,

E-mail: o051nm@yandex.ru

Dmitry G. Blinov, postgraduate student at Gagarin State Technical University, Saratov, Russia,

E-mail: bdg@rusptk.com

ANNOTATION

The article provides a comprehensive analysis of the safety of autonomous vehicles as a promising solution to the global problem of road traffic injuries. Based on up-to-date data for 2023-2025 from international sources (NHTSA, Waymo, AAA), a comparative assessment of the accident rate of unmanned and traditional vehicles is carried out. The technological potential of autonomous systems to eliminate the human factor, which is the main cause of an accident, is considered in detail. The key barriers to mass adoption are being investigated: technical limitations, cybersecurity issues, legal uncertainty, and a low level of public trust. In conclusion, strategic directions for the safe integration of technologies are formulated, including the development of a regulatory framework, increasing transparency of testing and improving artificial intelligence algorithms.

Keywords: self-driving cars, intelligent transport, road safety, autonomous vehicles, artificial intelligence, public perception, regulatory regulation.

Введение

Ежегодно в результате дорожно-транспортных происшествий гибнет около **1,3 миллиона человек** во всем мире, а дорожный травматизм является основной причиной смерти детей и молодых людей в возрасте 5-29 лет. Подавляющее большинство этих аварий вызвано человеческим фактором: превышением скорости, вождением в состоянии опьянения, отвлечением внимания. В поисках решения этой масштабной проблемы производители и технологические компании активно разрабатывают автономные транспортные средства, призванные исключить человеческие ошибки из уравнения безопасности. Данный анализ предлагает всесторонний обзор текущего состояния технологий, статистики безопасности, общественного восприятия и нормативно-правовой базы, определяющих будущее беспилотного транспорта.

1. Методология исследования

Настоящая работа представляет собой аналитический обзор. Сбор и анализ информации проводился на основе вторичных данных из открытых источников.

Критериями отбора источников являлись:

1. **Актуальность:** основной массив данных и отчетов охватывает период 2023-2025 гг., что позволяет отразить самое современное состояние проблемы;
2. **Авторитетность и верифицируемость:** использовались официальные отчеты государственных регуляторов (NHTSA), корпоративные отчеты о безопасности от ведущих разработчиков (Waymo), данные социологических опросов от крупных отраслевых ассоциаций (AAA), а также рецензируемые научные публикации;
3. **Релевантность:** отбирались материалы, напрямую касающиеся вопросов безопасности, статистики ДТП, технологий и общественного восприятия беспилотных автомобилей.

В работе применялся комплексный подход, включающий следующие методы анализа:

1. **Сравнительный анализ:** использовался для сопоставления показателей аварийности автономных и традиционных автомобилей, а также для оценки различий в общественном восприятии и подходах к нормативному регулированию в разных странах;
2. **Критический анализ статистических данных:** вместо прямого статистического моделирования основной упор был сделан на критическую оценку и интерпретацию существующих статистических отчетов. Этот метод позволил выявить методологические искажения в «сырых» данных об аварийности (например, систематическую ошибку отчетности и несопоставимость сред эксплуатации) и провести более корректное сравнение на основе тяжести последствий ДТП, а не их общего числа;
3. **Системный анализ:** позволил рассмотреть проблему безопасности не как изолированную техническую задачу, а как сложную систему, включающую взаимосвязанные элементы: технологические (сенсоры, ИИ), инфраструктурные (V2X), правовые (ответственность) и социальные (общественное доверие).

2. Классификация уровней автоматизации вождения

Для систематизации и унификации понятий в области автоматизации вождения широкое применение нашла классификация, разработанная Сообществом автомобильных инженеров (SAE International) в стандарте J3016. Данная классификация определяет шесть уровней автоматизации, от 0 до 5, которые описывают степень участия автоматизированной системы

в процессе управления транспортным средством (рис. 1).

SAE J3016 УРОВНИ АВТОМАТИЗАЦИИ ВОЖДЕНИЯ

	УРОВЕНЬ 0	УРОВЕНЬ 1	УРОВЕНЬ 2	УРОВЕНЬ 3	УРОВЕНЬ 4	УРОВЕНЬ 5
Что должен делать водитель?	Вы ведёте автомобиль, даже если ноги находятся не на педалях, а руки не на руле			Вы не ведёте автомобиль, если активированы функции автоматического вождения		
	Вы обязаны следить за электронными ассистентами и подруливать, разгоняться и тормозить при необходимости			Если система попросит, вы должны взять управление на себя	Электронные ассистенты не требуют от человека брать управление на себя	
	Системы помощи водителю			Системы беспилотного вождения		
Что делает автоматика?	Ассистенты лишь предупреждают и оказывают кратковременную помощь	Ассистенты помогают рулить ИЛИ ускоряться/тормозить	Ассистенты помогают рулить И ускоряться/тормозить	Система может самостоятельно вести автомобиль только при одновременном выполнении нескольких условий	Система может самостоятельно вести автомобиль при любых условиях	
Примеры систем	<ul style="list-style-type: none"> Автоматическое экстренное торможение; Предупреждение о слепых зонах; Предупреждение о покидании полосы 	<ul style="list-style-type: none"> Удержание в полосе ИЛИ Адаптивный круиз-контроль 	<ul style="list-style-type: none"> Удержание в полосе И Адаптивный круиз-контроль одновременно 	<ul style="list-style-type: none"> Ассистент движения в дорожных заторах 	<ul style="list-style-type: none"> Местное беспилотное такси; У автомобиля может не быть руля и педалей 	<ul style="list-style-type: none"> То же самое, что уровень 4, но способность автономного передвижения сохраняется везде

Рис. 1 – Уровни автоматизации вождения согласно SAE J3016 [1]

- Уровень 0 (Отсутствие автоматизации):** Водитель полностью контролирует все аспекты вождения. Системы могут лишь информировать или предупреждать (например, ABS).
- Уровень 1 (Помощь водителю):** Система осуществляет либо продольный, либо поперечный контроль. Примерами являются адаптивный круиз-контроль или система удержания в полосе.
- Уровень 2 (Частичная автоматизация):** Система способна одновременно осуществлять продольный и поперечный контроль в определенных условиях (например, на автомагистрали). Водитель обязан осуществлять непрерывный мониторинг дорожной ситуации и быть готовым в любой момент взять управление на себя.
- Уровень 3 (Условная автоматизация):** Система полностью управляет автомобилем в определенных условиях, водитель может не следить за дорогой, но должен быть готов перехватить управление по запросу системы. Роль водителя определяется как «резервная».
- Уровень 4 (Высокая автоматизация):** Система обеспечивает полный контроль над движением в пределах определенной, заранее заданной среды (например, на трассах с высокодетализированными картами). Вмешательство водителя не требуется, пока автомобиль находится в этой среде.
- Уровень 5 (Полная автоматизация):** Система способна выполнять все функции вождения в любых условиях, которые может осилить водитель-человек. Наличие органов ручного управления не является обязательным. На сегодняшний день, согласно отраслевым отчетам, технологии 5-го уровня не реализованы.

Оценка текущего состояния внедрения высокоавтоматизированных автотранспортных средств (ВАТС) в мире и в Российской Федерации показывает доминирование систем 0-2 уровней на коммерческом рынке, в то время как уровни 3-4 находятся на стадии пилотных проектов и тестовой эксплуатации (рис. 2).



Рис. 2 – Текущее состояние по этапам внедрения автомобилей с различными уровнями автоматизации в мире и в Российской Федерации

3. Безопасная интеграция ВАТС: среда штатной эксплуатации и требования к инфраструктуре

Ключевым условием безопасного внедрения ВАТС является их поэтапная интеграция в существующую транспортную систему. Концепция обеспечения безопасности дорожного движения выделяет три фундаментальных компонента:

1. **Безопасность через ситуационную осведомленность ВАТС**, достигаемая за счет использования возможностей дорожно-транспортной инфраструктуры (ДТИ).
2. **Безопасность через функциональные возможности ВАТС**, включая обмен информацией между транспортными средствами (V2V).
3. **Безопасность через организацию дорожного движения** с помощью интеллектуальных транспортных систем (ИТС).

Для митигации рисков, связанных с эксплуатацией ВАТС, вводится понятие среды штатной эксплуатации (СШЭ) – строго определенного набора условий, в которых автоматизированная система вождения (АСВ) может функционировать надежно (рис. 3). СШЭ регламентирует такие параметры, как тип дороги, диапазон скоростей, географические и погодные условия, а также требования к наличию инфраструктурной поддержки.

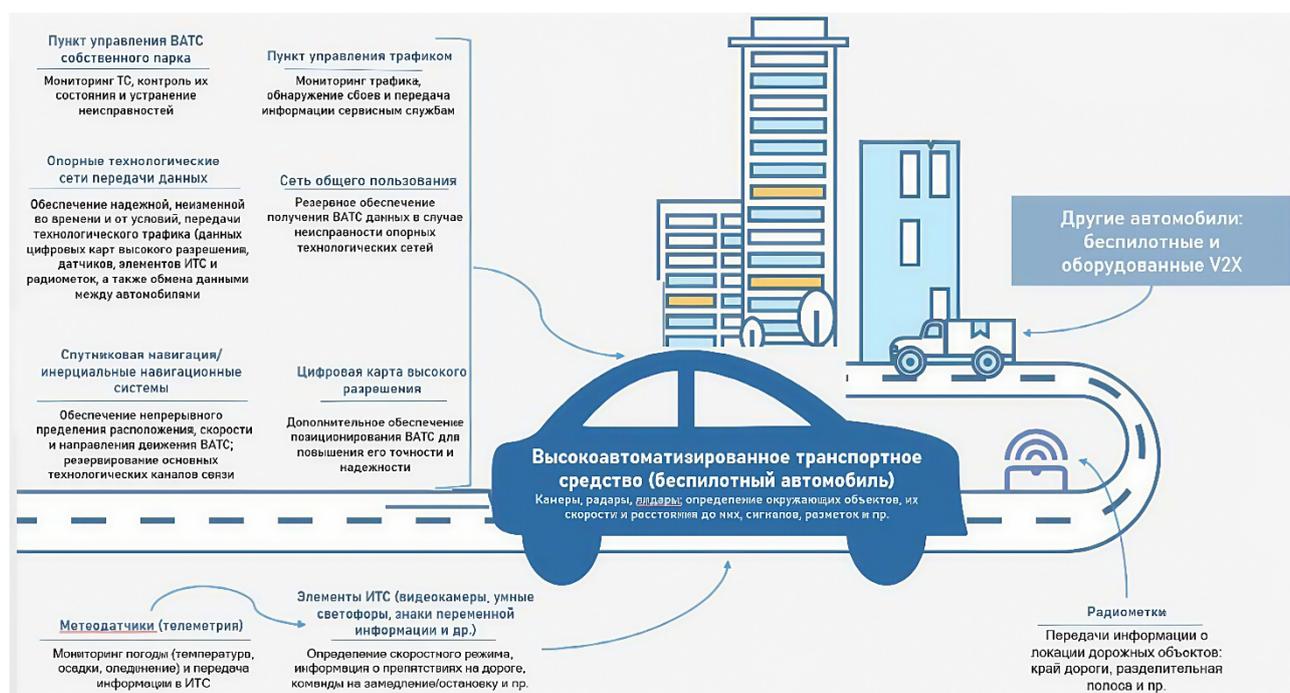


Рис. 3 – Обобщенная схема инфраструктурного окружения ВАТС

Выделяется три типа СШЭ:

1. **СШЭ первого типа:** ВАТС функционирует автономно, полагаясь исключительно на бортовые сенсоры и статические карты. Скорость движения ограничивается дальностью уверенного распознавания объектов сенсорами.
2. **СШЭ второго типа:** ВАТС дополнительно использует динамическую цифровую карту высокого разрешения, что позволяет прогнозировать появление помех и превентивно корректировать скоростной режим.
3. **СШЭ третьего типа:** Обеспечивается полное сетевое взаимодействие ВАТС с ДТИ и другими участниками движения (V2X). АСВ получает исчерпывающую информацию о дорожной обстановке в реальном времени, что позволяет двигаться с максимально возможной безопасной скоростью.

Для реализации СШЭ третьего типа и обеспечения безопасного движения ВАТС к дорожно-транспортной инфраструктуре предъявляется ряд строгих требований. Обобщенная схема инфраструктурного окружения ВАТС представлена на рисунке 3. Ключевыми элементами являются:

1. Интеллектуальная транспортная система (ИТС), включающая подсистемы управления потоками, контроля правил дорожного движения (ПДД), информирования и т.д.
2. Система высокоточного позиционирования на основе спутниковых технологий (ГНСС) с дифференциальной коррекцией от сети референчных базовых станций.
3. Цифровая модель дороги (ЦМД) – динамическая высокоточная карта, содержащая сведения о геометрии дороги, разметке, знаках, а также данные о дорожной обстановке в реальном времени.
4. Устойчивое покрытие высокоскоростными сетями связи для обеспечения непрерывного обмена данными.

4. Технологии взаимодействия V2X (Vehicle-to-Everything)

Эффективное функционирование ВАТС в смешанном транспортном потоке невозможно без организации информационного обмена между всеми его участниками. Эта парадигма получила название V2X (Vehicle-to-Everything) и включает следующие типы взаимодействия:

1. **V2V (Vehicle-to-Vehicle):** Прямой обмен данными между транспортными средствами для координации маневров и предотвращения столкновений.
2. **V2I (Vehicle-to-Infrastructure):** Взаимодействие транспортного средства с элементами дорожной инфраструктуры (светофорами, дорожными контроллерами RSU).
3. **V2C (Vehicle-to-Cloud/Center):** Связь с центральной платформой интеллектуальной транспортной системы (ИТС) для получения данных о трафике, маршрутах и обновления ЦМД.
4. **V2P (Vehicle-to-Pedestrian):** Информирование о приближении пешеходов и других уязвимых участников движения.

Для реализации V2X-коммуникаций на сегодняшний день конкурируют два основных технологических стандарта:

1. **ITS-G5:** Основан на стандарте Wi-Fi 802.11p (DSRC), характеризуется низкой задержкой и предназначен для прямой связи на коротких дистанциях. Принят в качестве основного в Европе.
2. **C-V2X (Cellular-V2X):** Использует технологии сотовой связи (LTE, 5G). Обладает двумя режимами работы: прямая связь с низкой задержкой (интерфейс PC5) и связь через сотовую сеть (интерфейс Uu) для некритичных ко времени задач. Данная технология принята в качестве основной в Китае.

Переход к широкой эксплуатации высокоавтоматизированных транспортных средств является системной задачей, выходящей за рамки совершенствования самого автомобиля. Успешное и безопасное внедрение ВАТС напрямую зависит от создания комплексной цифровой экосистемы, включающей интеллектуальную дорожную инфраструктуру, системы высокоточного позиционирования, динамические цифровые модели дорог и стандартизированные технологии V2X-взаимодействия. Определение и нормативное закрепление сред штатной эксплуатации для различных уровней автоматизации является ключевым механизмом управления рисками на начальных этапах интеграции беспилотного транспорта в дорожное движение.

5. Технологический ландшафт: что движет беспилотниками?

Теоретический потенциал автономных транспортных средств для спасения жизней огромен. В отличие от людей, машины не устают, не отвлекаются на сообщения в телефоне и не управляют транспортом в состоянии алкогольного или наркотического опьянения. Однако эта надежность обеспечивается сложным комплексом технологий, каждая из которых вносит свой вклад в общую безопасность.

1. **Ликвидация человеческого фактора:** Беспилотные системы могут быть запрограммированы на неукоснительное соблюдение правил дорожного движения, включая ограничения скорости и дистанции. Они способны антиципировать потенциальные опасности и реагировать на них быстрее, чем человек, благодаря комплексу датчиков (лидары, радары, камеры), которые постоянно сканируют окружающее пространство на 360 градусов. Современные системы искусственного интеллекта, построенные на передовых фреймворках, таких как PyTorch и TensorFlow, позволяют обрабатывать эти данные в реальном времени, распознавая пешеходов, другие транспортные средства и дорожные знаки [2].

2. **Обеспечение безопасности пассажиров:** Автономные автомобили могут быть оснащены системами, которые не только напоминают, но и обеспечивают использование ремней безопасности всеми пассажирами, а также корректную установку детских удерживающих устройств.
3. **Оптимизация дорожного движения:** Сети взаимодействующих друг с другом беспилотников (технология V2X – Vehicle-to-Everything) могут координировать свои действия, что позволяет снизить заторы, минимизировать резкие торможения и, как следствие, уменьшить количество аварий, вызванных «эффектом гармошки». Это направление активно развивается в рамках исследований по оптимизации логистики и расписаний (Vehicle Routing Problem – VRP), которые напрямую связывают со снижением операционных расходов (ОРЕХ) и повышением пропускной способности дорог [3].

Таблица 1

Ключевые технологические компоненты беспилотного автомобиля и их функции

Компонент	Принцип работы	Основная функция	Преимущества	Ограничения
Лидар (LiDAR)	Испускает лазерные импульсы и измеряет время их возврата	Построение высокоточного 3D-карты окружающего пространства	Высокая точность измерения дистанции, работает в темноте	Чувствителен к плотному дождю, снегу; высокая стоимость
Радар (Radar)	Излучает радиоволны и улавливает отраженные сигналы	Измерение скорости и дистанции до объектов, работа в плохую погоду	Надежно работает в дождь, туман, снегопад	Низкое разрешение, сложность в определении типа объекта
Компьютерное зрение (Камеры)	Запись и анализ видеопотоков с помощью нейросетей	Распознавание объектов, цветов, чтение дорожных знаков, детализация	Способность распознавать мелкие объекты (жесты, мимика)	Зависимость от освещенности, возможность ослепления

6. Текущие данные и статистика: обещания против реальности

Несмотря на оптимистичные прогнозы, реальные данные, особенно касающиеся систем второго уровня автономности (уровень 2 ADAS), которые все еще требуют постоянного внимания водителя, рисуют неоднозначную картину. Анализ актуальной статистики требует чрезвычайной осторожности, чтобы отделить рекламные заявления от фактических результатов и не попасть в ловушку некорректных сравнений.

По данным Национального управления безопасностью движения на трассах США (NHTSA), количество сообщений об авариях с участием автомобилей, оснащенных системами автоматического вождения (ADS), продолжает расти. Например, в мае 2025 года был зафиксирован рекордный месячный показатель в 110 столкновений (рис. 4) [4].

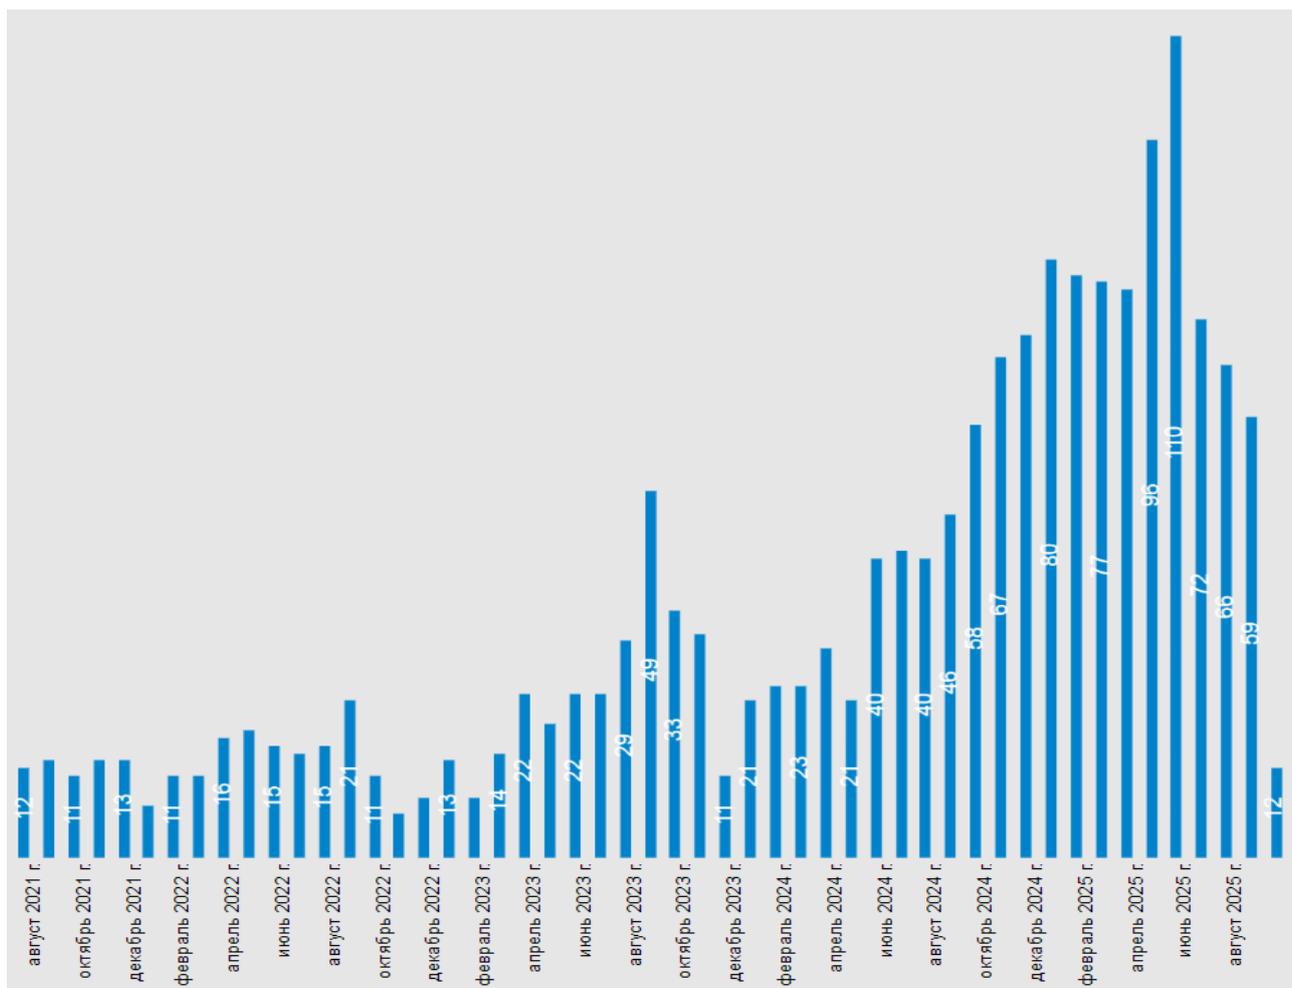


Рис. 4 – Число столкновений автомобилей, оснащенных системами автоматического вождения (ADS) на трассах США по состоянию на 15 сентября 2025 года [4]

Более того, некоторые аналитические отчеты приводят на первый взгляд тревожную статистику. Так, один из показателей составляет 5,6 аварии на миллион километров для беспилотников против 2,6 аварии для автомобилей под управлением человека (рис. 5) [5].

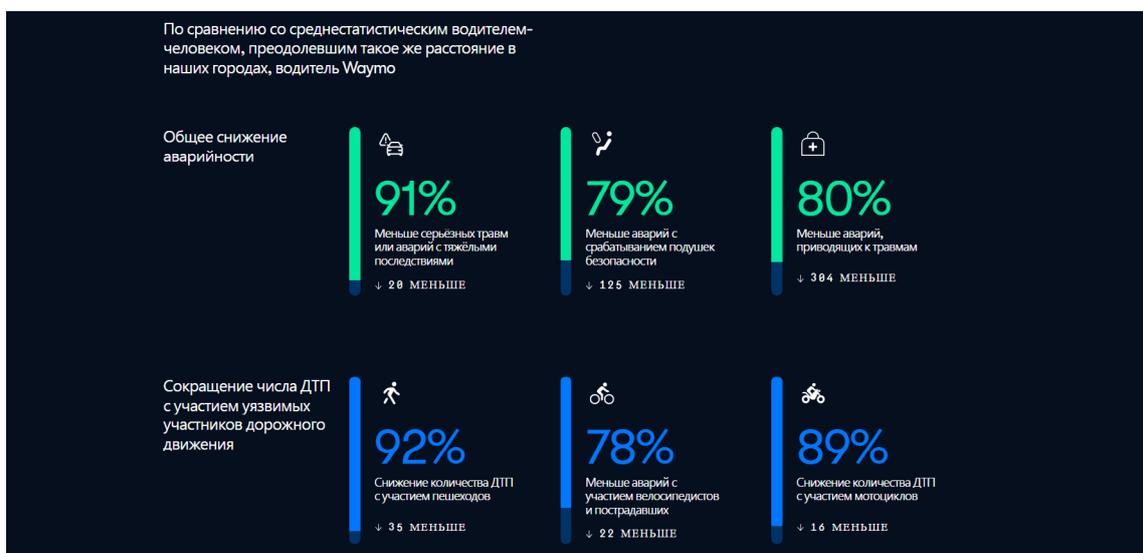


Рис. 5 – Сравнение аварийности с участием среднестатистического водителя-человека и автомобиля Waymo

Однако прямое сопоставление этих «сырых» цифр является методологически некорректным и вводит в заблуждение по ряду фундаментальных причин, которые необходимо разъяснить.

Критический анализ данных об аварийности:

1. Систематическая ошибка отчетности: Беспилотные автомобили (БПА) оснащены телеметрией, которая фиксирует и передает регулятору данные о любом инциденте, включая малейшее касание бампером на парковке, которое водитель-человек даже не заметил бы. Статистика по людям, напротив, основана преимущественно на полицейских отчетах, которые составляются только для более-менее серьезных ДТП. Подавляющее большинство мелких инцидентов никогда не попадает в официальную статистику. Таким образом, мы сравниваем почти 100% отчетность БПА с верхушкой айсберга человеческих ДТП.
2. Несопоставимость сред эксплуатации (ODD): Тестирование беспилотных такси (Уровень 4) проходит в основном в сложнейших городских условиях (Сан-Франциско, Финикс) с высокой плотностью трафика, пешеходов и непредвиденных ситуаций, где частота инцидентов объективно выше. Статистика по человеку «размыта» за счет огромного пробега по относительно безопасным загородным трассам.
3. Проблема определения вины: Анализ отчетов показывает, что в подавляющем большинстве инцидентов с участием БПА (более 90% случаев) виновником был водитель-человек, который, например, врезался сзади в остановившийся по правилам беспилотник. Формально БПА становится «участником» ДТП и попадает в статистику, не будучи его причиной.

Понимание этих искажений позволяет перейти к более корректному анализу. Вместо сравнения общего числа «касаний» следует оценивать тяжесть последствий на сопоставимых территориях [6-8]. Именно такой подход используют компании-лидеры, как Waymo. В своих отчетах они сравнивают показатели своих БПА с усредненными человеческими показателями в тех же самых городах. Результаты такого анализа гораздо более показательны (таблица 2).

По данным Waymo, их технология обеспечила на 91% меньше аварий с серьезными травмами и на 80% меньше аварий с любыми травмами по сравнению с водителями-людьми на тех же маршрутах [9]. Это демонстрирует ключевое преимущество БПА: даже если они не могут избежать всех мелких инцидентов (часто по вине других), их предсказуемое и законопослушное поведение помогает предотвращать именно опасные, травматичные столкновения [10, 11].

Дополнительные исследования подтверждают потенциал технологии. Анализ данных электроэнцефалографии (ЭЭГ) пассажиров показал, что алгоритмы могут предсказывать агрессивные маневры с точностью до 93,61%, что открывает путь к созданию еще более плавных и безопасных систем [7].

Таблица 2

Сравнительный анализ ключевых показателей безопасности (данные за 2023-2025 гг.)

Показатель	Беспилотные автомобили (уровень 4, e.g., Waymo)	Традиционные автомобили (с человеком за рулем)	Источник данных
Аварии с серьезными травмами	На 91% ниже	Усредненный показатель по городам тестирования	Waymo Safety Impact Report [6]
Аварии с любыми травмами	На 80% ниже	Усредненный показатель по городам тестирования	Waymo Safety Impact Report [6]

Показатель	Беспилотные автомобили (уровень 4, e.g., Waymo)	Традиционные автомобили (с человеком за рулем)	Источник данных
Общее количество инцидентов (на млн. миль)	9.1 (включая мелкие)	~4.1	Анализ данных департамента транспортных средств США (DMV) [5]
Предсказание водительских событий	93.61% (по данным ЭЭГ)	Не применяется	Исследование на основе ЭЭГ [7]

Таким образом, при правильной интерпретации данных становится очевидно, что технология высоких уровней автономности уже сегодня демонстрирует значительный потенциал в снижении тяжести ДТП, что является ее главной целью.

7. Препятствия на пути широкого внедрения: за пределами технологий

Даже если технология докажет свое превосходство в безопасности, ее повсеместное принятие столкнется с рядом комплексных вызовов, лежащих в технической, социальной, правовой и этической плоскостях.

- Недоверие общества:** Согласно последнему опросу Американской автомобильной ассоциацией (AAA), проведенному в феврале 2025 года, **шесть из десяти водителей в США** признаются, что боятся ездить в беспилотном автомобиле. Несмотря на небольшой рост по сравнению с предыдущим годом, лишь **13%** респондентов заявили, что доверяют этой технологии (рис. 6) [13]. Аналогичные тенденции наблюдаются и в других странах. Опрос в Китае показал, что, хотя более половины респондентов имели опыт поездки в беспилотном такси, вопросы безопасности и ответственности остаются для них ключевыми [14]. Высокий уровень скептицизма напрямую влияет на готовность потребителей платить за автономные функции и на политическую волю для их широкого одобрения.

Отношение водителей к беспилотным автомобилям

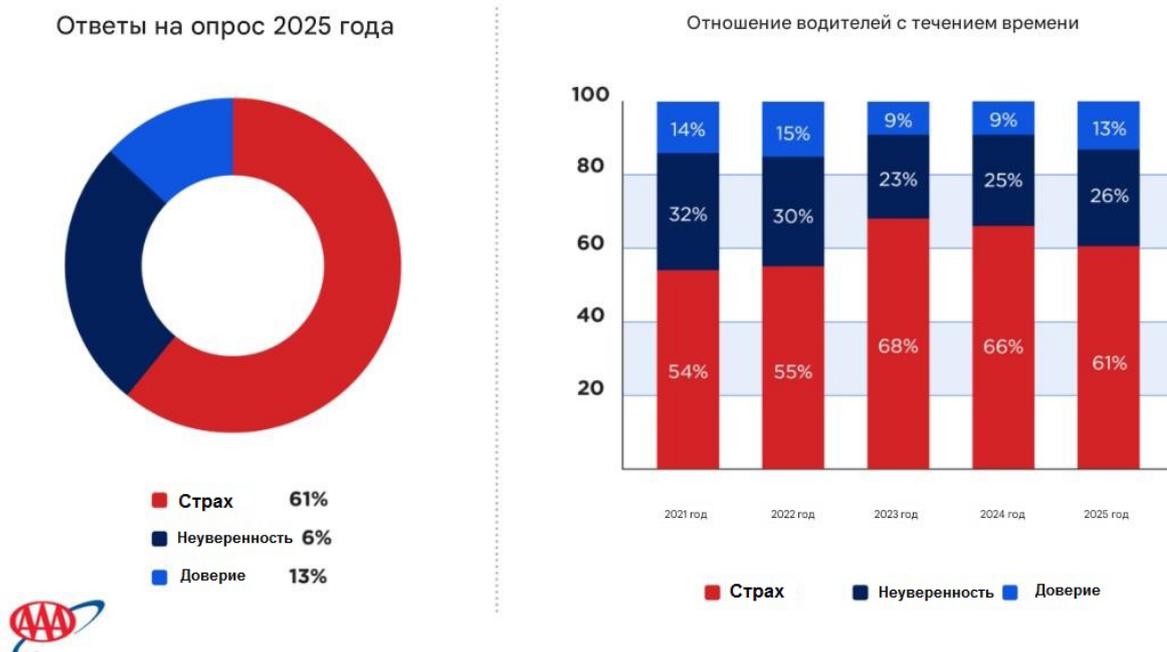


Рис. 6 – Отношение водителей к беспилотным транспортным средствам [13]

- **Проблема ответственности (Liability ambiguity):** В случае аварии беспилотного автомобиля возникает сложный юридический вопрос: кто виноват? Водитель (который не управлял машиной), производитель автомобиля, разработчик программного обеспечения или компания, обслуживающая парк? Единой нормативной базы, регулирующей эти вопросы, на сегодняшний день не существует [15]. Это создает правовую неопределенность, которая замедляет развертывание технологий и отпугивает страховые компании.
- **Кибербезопасность:** Высокая зависимость автономных автомобилей от программного обеспечения и подключения к сетям делает их потенциальной мишенью для хакерских атак. Угрозы варьируются от утечки данных пассажиров (маршруты, предпочтения) до, что еще опаснее, захвата контроля над критически важными системами – рулением, торможением, ускорением [16]. Производителям необходимо внедрять многоуровневые системы защиты, включая регулярные обновления безопасности и криптографическое шифрование каналов связи.
- **Технические и экологические ограничения:** Датчики беспилотных автомобилей (камеры, лидары) могут работать с перебоями в сложных погодных условиях: при сильном дожде, снегопаде или тумане. Нестандартные ситуации на дорогах, такие как действия дорожных рабочих или неисправность другого транспортного средства, также остаются серьезным испытанием для искусственного интеллекта. Алгоритмы глубокого обучения, включая нейронные сети, требуют огромного количества разнообразных данных для обучения, чтобы корректно реагировать на редкие, но опасные «пограничные случаи» (edge cases) [17].
- **Этические дилеммы и проблема «вагонетки»:** Помимо технических и правовых барьеров, одним из самых сложных является этический аспект принятия решений искусственным интеллектом, особенно в неизбежных аварийных ситуациях. Этот вызов часто иллюстрируется классическим мысленным экспериментом – «проблемой вагонетки» (Trolley Problem), адаптированной для беспилотных автомобилей.

Представим ситуацию, когда столкновение неизбежно. Как должен поступить автомобиль, если у него есть выбор:

1. Свернуть на тротуар и сбить группу пешеходов, чтобы спасти своего пассажира?
2. Пожертвовать пассажиром, продолжив движение прямо и врезавшись в препятствие, чтобы спасти пешеходов?
3. Выбирать между разными группами пешеходов (например, пожилые люди против детей, нарушители ПДД против тех, кто переходит по правилам)?

Эти вопросы не имеют простого ответа [18, 19].

- **Утилитарный подход** предписывает минимизировать общий ущерб, то есть пожертвовать одним человеком ради спасения пятерых. Однако это может означать, что автомобиль целенаправленно примет решение пожертвовать своим владельцем. Опросы показывают, что, хотя большинство людей считают утилитарный подход правильным для *других* автомобилей, они сами не хотели бы покупать машину, запрограммированную жертвовать ими [20].
- **Деонтологический подход** утверждает, что существуют абсолютные моральные правила (например, «не убей»), и машина не должна совершать активное действие, ведущее к чьей-либо гибели, даже во имя большего блага. Это может привести к парадоксальным решениям, когда автомобиль предпочтет бездействие, которое приведет к более тяжелым последствиям.
- **Проблема алгоритмической предвзятости:** Решения, которые будет принимать ИИ, зависят от данных, на которых он обучался, и от ценностей, заложенных в него программистами. Это поднимает вопросы о культурных различиях. Например, исследование MIT «Moral Machine» показало, что предпочтения в дилеммах «вагонетки» значительно различаются между странами [21]. Чьи этические нормы – европейские, американские или азиатские – должны быть заложены в глобальный продукт?

Отсутствие единого, согласованного на международном уровне подхода к программированию «машинной этики» является серьезным препятствием. Это не просто техническая задача, а глубокая философская и социальная проблема, требующая широкого общественного диалога и выработки прозрачных нормативных принципов.

8. Взгляд в будущее: стратегические направления для безопасной интеграции

Для реализации потенциала беспилотных автомобилей в спасении жизней необходим комплексный подход, выходящий за рамки лабораторных испытаний:

1. **Развитие нормативно-правовой базы:** Государственным органам необходимо разработать четкие и единообразные стандарты безопасности для тестирования и эксплуатации автономного транспорта, а также законы, регулирующие вопросы ответственности и страхования. Это включает в себя создание «песочниц» для испытаний, утверждение процедур сертификации и установление требований к сбору и обмену данными об инцидентах.
2. **Повышение прозрачности и информированности:** Производители должны делиться агрегированными данными о безопасности, как это делает Waymo, чтобы независимые эксперты могли проводить анализ, а общественность – формировать реалистичные ожидания. Публичные демонстрационные поездки и образовательные кампании могут помочь развеять мифы и показать реальные возможности технологий.
3. **Совершенствование технологий и данных:** Необходимо продолжать работу над повышением надежности сенсоров и алгоритмов, особенно в сложных и непредсказуемых условиях. Ключевым аспектом является качество данных для обучения ИИ. Принцип «мусор на входе – мусор на выходе» как никогда актуален: для создания беспристрастных и надежных моделей требуются качественные, разнообразные и хорошо размеченные данные. Развитие концепции «умных дорог», взаимодействующих с автомобилями (Vehicle-to-Everything, V2X), также может значительно повысить общий уровень безопасности, предоставляя транспортным средствам дополнительный канал информации о дорожной обстановке.

- 4. Разработка этических рамок и борьба с предвзятостью:** Необходимо инициировать широкий общественный и междисциплинарный диалог для выработки прозрачных этических принципов принятия решений для ИИ. Эти принципы должны быть закреплены в нормативных актах. Алгоритмы должны разрабатываться и тестироваться на предмет отсутствия предвзятости по отношению к различным группам участников движения. Печально известный пример инструмента найма от Amazon, который дискриминировал женщин, служит предостережением для автомобильного сектора [22]. Беспилотные системы должны быть справедливы и надежны для всех участников дорожного движения.

Заключение

Проведенный комплексный анализ показывает, что эра безопасного автономного транспорта наступит не в результате единичного технологического прорыва, а только через построение целостной социально-технической экосистемы. Основным выводом исследования заключается в том, что парадигма развития беспилотных автомобилей смещается от чисто технологической гонки к решению системных задач в правовой, этической и инфраструктурной плоскостях.

Анализ статистики аварийности убедительно демонстрирует, что прямое сравнение «человек против машины» по общему числу инцидентов является методологически несостоятельным. Ключевой перспективой и реальным показателем успеха технологии является ее доказанная способность – как в случае с Waymo – радикально снижать тяжесть последствий ДТП, предотвращая аварии с пострадавшими. Это означает, что стратегической целью должно быть не создание «безаварийного» автомобиля в абсолюте, а внедрение системы, минимизирующей наиболее опасные риски, присущие человеческому фактору.

В то же время, анализ барьеров показывает, что технические ограничения (например, работа в плохую погоду) сегодня уступают по значимости «мягким» проблемам: правовому вакууму в вопросах ответственности, отсутствию консенсуса по этическим дилеммам и глубокому общественному недоверию. Эти вызовы не могут быть решены исключительно инженерными методами и требуют выработки новых социальных контрактов и регуляторных механизмов.

Исходя из этого, наиболее реалистичной стратегической перспективой является не массовое и одномоментное внедрение универсальных ВАС 5-го уровня, а поэтапная, гетерогенная интеграция технологии в строго определенных средах штатной эксплуатации (СШЭ). Перспективными направлениями становятся:

1. Развертывание полностью автономных грузовых коридоров на автомагистралях, где среда наиболее предсказуема.
2. Создание геоограниченных зон для беспилотных такси и шаттлов в городских центрах с развитой V2X-инфраструктурой.
3. Использование систем более низкого уровня (L2-L3) в качестве продвинутых помощников водителя, а не его полной замены, на большинстве дорог общего пользования.

Таким образом, задача заключается не в том, чтобы создать «идеального водителя» в вакууме, а в том, чтобы спроектировать «идеальную транспортную систему» для каждой конкретной среды, где технология, инфраструктура, право и ожидания общества находятся в гармонии. От успеха этого системного проектирования зависит, станет ли беспилотный автомобиль символом новой эпохи безопасности или останется сложной технологической задачей с нереализованным потенциалом.

Список использованной литературы

1. *Automated driving levels of driving automation are defined in new SAE international standard J3016* [Электронный ресурс]. – URL: <https://templatelab.com/automated-driving/> (дата обращения: 30.10.2025).
2. D. Petrović, R. Mijailović, and D. Pešić, “Traffic Accidents with Autonomous Vehicles: Type of Collisions, Manoeuvres and Errors of Conventional Vehicles’ Drivers,” *Transportation Research Procedia*, 2020. DOI: 10.1016/j.trpro.2020.03.112.
3. N. M. Proma, G. Vázquez, S. Shahbeigi, A. Badyal, and V. Hodge, “Probabilistic Safety Verification for an Autonomous Ground Vehicle: A Situation Coverage Grid Approach,” in *2025 IEEE Int. Conf. Veh. Electron. Saf.*, 2025. [Online]. Available: <https://doi.org/10.21203/rs.3.rs-3401212/v1>.
4. *Self-Driving Car Accidents Trend Chart (2025)* [Электронный ресурс]. – URL: <https://www.consumershield.com/articles/self-driving-car-accidents-trends> (дата обращения: 30.10.2025).
5. *Self-Driving Car Crash Statistics* [Электронный ресурс]. – URL: <https://www.pstriallaw.com/legal-news/self-driving-car-accident-statistics> (дата обращения: 30.10.2025)
6. B. Kutela, S. Das, and B. Dadashova, “Mining patterns of autonomous vehicle crashes involving vulnerable road users to understand the associated factors,” *Accident Analysis & Prevention*, 2022. DOI: 10.1016/j.aap.2021.106473.
7. B. Kutela et al., “Leveraging autonomous vehicles crash narratives to understand the patterns of parking-related crashes,” *Traffic Safety Research*, 2023. DOI: 10.55329/fiqq8731.
8. S. Kim, M. Cho, and Y. Lee, “Exploration of Traffic Accident-Based Pilot Zones for Autonomous Vehicle Safety Validation,” *Electronics*, vol. 13, no. 17, p. 3390, 2024. DOI: 10.3390/electronics13173390.
9. *Waymo Safety Impact* [Электронный ресурс]. – URL: <https://waymo.com/safety/impact/> (дата обращения: 30.10.2025).
10. A. M. Al-Emran, “A case study of unavoidable accidents of autonomous vehicles,” in *2023 Int. Conf. Intell. Syst. Comput. Vis. (ISCIV)*, 2023. DOI: 10.1109/ISCIV59145.2023.10144969.
11. M. Abdel-Aty and S. Ding, “A matched case-control analysis of autonomous vs human-driven vehicle accidents,” *Nature Communications*, vol. 15, p. 3524, 2024. DOI: 10.1038/s41467-024-48526-4.
12. EEG-based prediction of driving events from passenger cognitive state using Morlet Wavelet and Evoked Responses // *Transportation Engineering*. – 2022. – doi: 10.1016/j.treng.2022.100107.
13. *AAA: Fear in Self-Driving Vehicles Persists* [Электронный ресурс]. – URL: <https://newsroom.aaa.com/2025/02/aaa-fear-in-self-driving-vehicles-persists/> (дата обращения: 30.10.2025).
14. Отчет об опросе, посвященном осведомленности общественности и ожиданиям в отношении беспилотных автомобилей (2025) [Электронный ресурс]. – URL: <https://www.rmlt.com.cn/2025/0908/739212.shtml> (дата обращения: 30.10.2025).
15. B. Wang, “Approaches to Autonomous Driving Vehicle Traffic Accidents Liability in China,” *Lecture Notes in Education Psychology and Public Media*, vol. 26, p. 437, 2023. DOI: 10.54254/2753-7048/26/20230901.
16. *Automated Vehicles for Safety* [Электронный ресурс]. – URL: <https://www.nhtsa.gov/vehicle-safety/automated-vehicles-safety> (дата обращения: 30.10.2025).
17. Решения по обработке данных для обучения с использованием ИИ: что изменится в 2025 году? [Электронный ресурс]. – URL: <https://ru.macgence.com/blog/ai-training-data-solutions-whats-changing-in-2025/> (дата обращения: 30.10.2025).
18. C. D. Wallbridge, ““Warning!” Benefits and Pitfalls of Anthropomorphising Autonomous Vehicle Informational Assistants in the Case of an Accident,” *Multimodal Technologies and Interaction*, vol. 8, no. 12, p. 110, 2024. DOI: 10.3390/mti8120110.
19. M. M. Mayer, A. Buchner, and R. Bell, “Humans, machines, and double standards? The moral evaluation of the actions of autonomous vehicles, anthropomorphized autonomous vehicles, and human drivers in road-accident dilemmas,” *Transportation Research Part F: Traffic Psychology and Behaviour*, vol. 93, pp. 430–442, 2023. DOI: 10.1016/j.trf.2023.02.015.
20. J.-F. Bonnefon, A. Shariff, and I. Rahwan, “The Social Dilemma of Autonomous Vehicles,” *Science*, vol. 352, no. 6293, pp. 1573–1576, 2016. DOI: 10.1126/science.aaf2654.
21. E. Awad, S. Dsouza, R. Kim et al., “The Moral Machine experiment,” *Nature*, vol. 563, pp. 59–64, 2018. DOI: 10.1038/s41586-018-0637-6.
22. *Amazon Created a Hiring Tool Using A.I. It Immediately Started Discriminating Against Women* [Электронный ресурс]. – URL: <https://slate.com/business/2018/10/amazon-artificial->



КОНТАКТЫ

Редакция
+7 (495) 967-77-01
journal@vniias.ru

Адрес
АО «НИИАС»,
Россия, г. Москва, Орликов переулок, д.5, стр.1 ком. 824 1

+7 (495) 967-77-06
info@vniias.ru

