

Издательский дом

МЕДИА ПАБЛИШЕР

Научный журнал "Т-Сomm: Телекоммуникации и транспорт"

Журнал включен в перечень периодических научных изданий, рекомендуемый ВАК Минобрнауки России для публикации научных работ, отражающих основное научное содержание кандидатских и докторских диссертаций

Журнал зарегистрирован Федеральной службой по надзору за соблюдением законодательства в сфере массовых коммуникаций и охране культурного наследия

Свидетельство о регистрации СМИ:

ПИ № ФС77-55956.

Дата выдачи: 07 ноября 2013 г.

Язык публикации: русский, английский.

Территория распространения:

Российская Федерация, зарубежные страны

Тираж: 1000 экз.

Периодичность выхода: 12 номеров в год

Стоимость одного экземпляра: 1000 руб.

Плата с аспирантов за публикацию рукописи не взимается

Предпечатная подготовка:

ООО "ИД Медиа Паблишер"

Мнения авторов не всегда совпадают с точкой зрения редакции.
За содержание рекламных материалов редакция ответственности не несет

Материалы, опубликованные в журнале — собственность ООО "ИД Медиа Паблишер". Перепечатка, цитирование, дублирование на сайтах допускаются только с разрешения издателя

© ООО "ИД Медиа Паблишер", 2026

Адрес редакции и издателя

111024, Россия, Москва, ул. Авиамоторная,
д. 8, стр. 1, офис 323

e-mail: t-comm@media-publisher.ru

Тел.: +7 (495) 957-77-43

Адрес типографии

Москва, ул. Складочная, д. 3, корп. 6

Индексация журнала:

Ulrich's Periodicals Directory; RSCI; EBSCO; elibrary.ru (ПИНЦ)
Google Scholar; CyberLeninka (Open Science);
Bielefeld Academic Search Engine (BASE); OCLC WorldCat;
Registry of Open Access Repositories (ROAR)

Journal is registered by Federal Service for monitoring compliance with cultural heritage protection law

ISSN 2072-8743 (Online) ISSN 2072-8735 (Print)

Media Registration Certificate

PI No. FS77-55956. Date of issue: November 7, 2013

Publication language: Russian, English.

Distribution Territory: Russian Federation, foreign countries

All articles and illustrations are copyright. All rights reserved.

No reproduction is permitted in whole or part without the express consent of
Media Publisher Joint-Stock Company

© "Media Publisher", 2026

Editorial and Publisher Address

111024, Russia, Moscow, Aviamotornaya str. 8, bloc 1, office 323

e-mail: t-comm@media-publisher.ru

Tel.: +7 (495) 957-77-43

ИЗДАТЕЛЬСКИЙ ДОМ МЕДИА ПАБЛИШЕР



ПОЛНЫЙ ЦИКЛ ПОДГОТОВКИ КНИГ, ПЕРИОДИЧЕСКИХ ИЗДАНИЙ И РЕКЛАМНОЙ ПРОДУКЦИИ

ПРОФЕССИОНАЛЬНОЕ ЛИТЕРАТУРНОЕ И ТЕХНИЧЕСКОЕ РЕДАКТИРОВАНИЕ

ВЫСОКОКАЧЕСТВЕННАЯ ОФСЕТНАЯ И ЦИФРОВАЯ ПЕЧАТЬ

www.media-publisher.ru

Журнал включен в перечень периодических научных изданий, рекомендуемый ВАК Минобрнауки России для публикации научных работ, отражающих основное научное содержание кандидатских и докторских диссертаций

Учредитель

ООО "Издательский дом Медиа Паблишер"

Главный редактор

Тихвинский Валерий Олегович

Издатель

Дымкова Светлана Сергеевна
ds@media-publisher.ru

Редакционная коллегия

Аджемов Артём Сергеевич

(д.т.н., профессор МТУСИ), Россия

Анютин Александр Павлович

(д.ф.-м.н., профессор, член программного и оргкомитетов WSEAS), Россия, Мексика

Бестугин Александр Роеальдович

(д.т.н., профессор ГУАП), Россия

Вааль Альберт

(д.т.н., старший научный сотрудник Ганноверского университета им. Лейбница на кафедре коммуникационной техники), Германия

Варламов Олег Витальевич

(д.т.н., в.н.с. МТУСИ), Россия

Головачев Юлиус

(управляющий консультант Detecon International GmbH), Германия

Гребенников Андрей Викторович

(Sumitomo Electric Europe), Великобритания

Данилов Владимир Григорьевич

(д.ф.-м.н., профессор МИЭМ, НИУ ВШЭ), Россия

Дулкейтс Эрик

(д.т.н., старший исполнительный директор корпорации Detecon), Силиконовая долина, США

Елизаров Андрей Альбертович

(д.т.н., профессор МИЭМ, НИУ ВШЭ), Россия

Ибрагимов Байрам

(д.т.н., профессор Азербайджанского технического университета, АзТУ), Азербайджан

Корбетт Ровэлл

(д.т.н., директор по исследованиям в научно-исследовательском центре China Mobile Research Institute, профессор университета Назарбаева), Гон-Конг (Китай), США

Кузовкова Татьяна Алексеевна

(д.э.н., декан экономического факультета МТУСИ), Россия

Лазарева Галина Геннадьевна

(член-корр. РАН, д.ф.-м.н., профессор РАН, РУДН), Россия

Лернер Илья Михайлович

(д.т.н., КНИТУ-КАИ), Россия

Ныркв Анатолий Павлович

(д.т.н., профессор, ГУМРФ им. академика С.О. Макарова), Россия

Омельянов Георгий Александрович

(д.ф.-м.н., Университет де Сонора, факультет математики, Эрмосильо), Мексика

Самойлов Александр Георгиевич

(д.т.н., профессор Владимирского государственного университета им. А.Г. и Н.Г. Столетовых), Россия

Сысоев Николай Николаевич

(д.ф.-м.н., декан физического факультета МГУ им. М.В. Ломоносова), Россия

Чиров Денис Сергеевич

(д.т.н., профессор МТУСИ), Россия

Шаврин Сергей Сергеевич

(д.т.н., профессор МТУСИ), Россия

Шарп Майкл

(д.э.н., Европейский институт стандартизации – ETSI), Великобритания

Яшина Марина Викторовна

(д.т.н., профессор, МТУСИ), Россия

СОДЕРЖАНИЕ

ЭЛЕКТРОНИКА. РАДИОТЕХНИКА

Ненашев В.А., Ненашев С.А., Клешнин Б.Д.

Методика совмещения разноракурсных потоков радиолокационных видеокадров в двухпозиционной системе бортовых

4

Смирнов П.И., Валяев О.А., Баурова Н.И., Мазлумян Г.С., Субботин Б.С.

Оценка точности UWB-дальнометрии для позиционирования карьерной техники в сложной радиосредке

12

ИНФОРМАТИКА

Татарникова Т.М., Янковский Н.А.

Адаптивный протокол маршрутизации для маломощных mesh-сетей интернета вещей

22

Шелухин О.И., Осин А.В.

Обнаружение редкой аномальной активности пользователей информационной системы методами машинного обучения

29

ТРАНСПОРТ

Фадюшин А.А., Петров А.И., Лихайрова Е.В., Шепелёв В.Д.

Анализ статуса маршрутной системы городского пассажирского транспорта общего пользования

39

ПУБЛИКАЦИИ НА АНГЛИЙСКОМ ЯЗЫКЕ

СВЯЗЬ

Тарасов В.Н., Бахарева Н.Ф.

Численно-аналитическое и имитационное моделирование системы массового обслуживания с гиперэрланговским распределением входного потока

49

ТРАНСПОРТ

Полянцев К.А., Городничев М.Г., Кулагин В.П.

Адаптивное управление светофорами на основе обучения с подкреплением с учетом потоков транспортных средств и пешеходов

57

CONTENT

ELECTRONICS. RADIO ENGINEERING

Nenashev V.A., Nenashev S.A., Kleshnin B.D.
Technique of combining different views of radar video shots
in a two-position system of on-board radars 4

Smirnov P.I., Valyaev O.A., Baurova N.I.,
Mazlumyan G.S., Subbotin B.S.
Assessment of UWB Ranging Accuracy for Positioning
Mining Trucks in a Complex Radio Environment 12

COMPUTER SCIENCE

Tatarnikova T.M., Yankovsky N.A.
Adaptive routing protocol for low-power mesh IoT networks 22

Sheluhin O.I., Osin A.V.
Detecting Rare User Behavior Anomalies in Information Systems
with Machine Learning 29

TRANSPORT

Fadyushin A.A., Petrov A.I., Lihayrova E.V., Shepelev V.D.
Analysis of the status of the route system of public urban
passenger transport 39

PUBLICATIONS IN ENGLISH

COMMUNICATIONS

Tarasov V.N., Bakhareva N.F.
Numerical-analytical and simulation modeling of a queuing
system with hyper-Erlang distribution of the input flow 49

TRANSPORT

Polyantseva K.A., Gorodnichev M.G., Kulagin V.P.
Adaptive traffic signal control based on reinforcement learning
with consideration of vehicle and pedestrian flows 57

T - C o m m

Telecommunications and transport

Volume 20. No. 5-2026

Release date: 20.05.2026

The journal is included in the list of scientific
publications, recommended Higher Attestation
Commission Russian Ministry of Education for the
publication of scientific works, which reflect the basic
scientific content of candidate and doctoral theses.

Founder: "Media Publisher", Ltd.

Publisher: Svetlana S. Dymkova
ds@media-publisher.ru

Editor in Chief: Dr. Valery O. Tikhvinskiy

Editorial board

Artem S. Adzhemov
Doctor of sciences, Professor MTUCI, *Russia*

Alexander P. Anyutin
Doctor of sciences, Professor, member of the program
and organizing committee WSEAS, *Russia, Mexico*

Aleksandr R. Bestugin
Doctor of sciences, Professor SUAI, *Russia*

Corbett Rowell
Full Professor: Electronic & Electrical Engineering
Nazarbayev University, *Hong Kong (China), USA*

Denis S. Chirov
Doctor of sciences, MTUCI, *Russia*

Vladimir G. Danilov
Doctor of sciences, Professor MIEM, HSE, *Russia*

Eric Dulkeyts
Ph.D., chief executive officer of the corporation Detecon, *USA*

Julius Golovachyov
Managing Consultant Detecon International GmbH, *Germany*

Andrey Grebennikov
Ph.D., Sumitomo Electric Europe, *United Kingdom*

Bayram Ibrahimov
Ph.D., Professor of Azerbaijan Technical University (AzTU),
Azerbaijan

Tatyana A. Kuzovkova
Doctor of sciences, MTUCI, *Russia*

Galina G. Lazareva
Corresponding Member, RAS, Doctor of sciences, Professor RAS,
RUDN, *Russia*

Ilya M. Lerner
Doctor of sciences, KNRTU-KAI, *Russia*

Anatoliy P. Nyrkov
Doctor of sciences, Professor of Admiral Makarov State University
of Maritime and Inland Shipping, *Russia*

Georgii A. Omel'yanov
Doctor of sciences, Universidad de Sonora,
Department of Mathematics, Hermosillo, *Mexico*

Alexander G. Samoilov
Doctor of sciences, VLSU, *Russia*

Michael Sharpe
PhD, European Standards Institute – ETSI, *United Kingdom*

Sergey S. Shavrin
Doctor of sciences, MTUCI, *Russia*

Nikolai N. Sysoev
Doctor of sciences, Dean of the Faculty of Physics
of Moscow State University Lomonosov, *Russia*

Oleg V. Varlamov
Doctor of sciences, MTUCI, *Russia*

Albert Waal
Ph.D., Senior Research Fellow University of Hanover. Leibniz
at the Department of Communications Technology, *Germany*

Marina V. Yashina
Doctor of sciences, Professor MTUCI, *Russia*

Andrey A. Yelizarov
Doctor of sciences, Professor MIEM, HSE, *Russia*

www.media-publisher.ru

МЕТОДИКА СОВМЕЩЕНИЯ РАЗНОРАКУРСНЫХ ПОТОКОВ РАДИОЛОКАЦИОННЫХ ВИДЕОКАДРОВ В ДВУХПОЗИЦИОННОЙ СИСТЕМЕ БОРТОВЫХ РЛС

DOI: 10.36724/2072-8735-2026-20-5-4-11

Ненашев Вадим Александрович,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, Санкт-Петербург, Россия,
nenashev.va@yandex.ru, nenashev@guap.ru

Manuscript received 10 February 2026;
Accepted 17 April 2026

Ненашев Сергей Александрович,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, Санкт-Петербург, Россия,
nenashev_sergey178@mail.ru

Исследование выполнено при финансовой поддержке
Российского научного фонда, проект № 24-79-10259

Клешнин Борис Денисович,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, Санкт-Петербург, Россия,
boria456@gmail.com

Ключевые слова: совмещение радиолокационных кадров, разноракурсные видеопотоки, малогабаритная РЛС, мониторинг в реальном времени, синтезированная апертура, локальные признаки

В задачах оперативного мониторинга земной поверхности с применением малогабаритных бортовых радиолокационных систем, размещённых на малых летательных аппаратах, возникает необходимость формирования единого совмещённого кадра на основе двух разноракурсных радиолокационных видеопотоков. Основная сложность заключается в наличии радиолокационных теней, геометрических искажений и неполного перекрытия кадров, что затрудняет их точное совмещение и последующий анализ. Целью работы является исследование и разработка методики совмещения разноракурсных радиолокационных видеок кадров, формируемых двухпозиционной пространственно-распределённой малогабаритной бортовой радиолокационной системой, для получения единого радиолокационного кадра. В работе проведён анализ современных методов и алгоритмов совмещения радиолокационных изображений, включая алгоритмы на основе локальных признаков, нейросетевые методы сопоставления и геометрически ориентированные подходы. По результатам анализа для основной процедуры сопоставления выбран метод LoFTR, обеспечивающий плотный поиск соответствий между областями изображений без предварительного выделения отдельных характерных точек. Предложенная методика включает использование данных GPS/ГЛОНАСС и инерциальной навигационной системы для предварительной геометрической привязки, подготовку радиолокационных кадров, извлечение и сопоставление признаков, фильтрацию ложных соответствий, оценку геометрического преобразования и формирование единой панорамы. Предложена методика совмещения двух разноракурсных радиолокационных видеопотоков. Использование LoFTR повышает устойчивость сопоставления при изменении ракурса, различиях радиометрической структуры кадров и недостатке выраженных локальных признаков. Полученные результаты показывают возможность формирования единого радиолокационного кадра на основе данных, поступающих от двух независимых МБРЛС. Предложенная методика может быть использована в задачах оперативного мониторинга земной поверхности, контроля критической инфраструктуры, экологического наблюдения, обнаружения аварийных ситуаций и поисково-спасательных операций.

Информация об авторах:

Ненашев Вадим Александрович, д.т.н., доцент, заведующий лабораторией машинного обучения проектно-технологического офиса инженерной школы, доцент кафедры "Конструирования и технологий электронных и лазерных средств" ГУАП, г. Санкт-Петербург, Россия

Ненашев Сергей Александрович, заведующий лабораторией промышленной электроники проектно-технологического офиса инженерной школы, младший научный сотрудник кафедры "Конструирования и технологий электронных и лазерных средств" ГУАП, аспирант ГУАП, г. Санкт-Петербург, Россия

Клешнин Борис Денисович, инженер лаборатории промышленной электроники проектно-технологического офиса инженерной школы, студент кафедры "Конструирования и технологий электронных и лазерных средств", магистрант ГУАП, г. Санкт-Петербург, Россия

Для цитирования:

Ненашев В.А., Ненашев С.А., Клешнин Б.Д. Методика совмещения разноракурсных потоков радиолокационных видеок кадров в двухпозиционной системе бортовых РЛС // Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 4-11.

For citation:

V. A. Nenashev, S. A. Nenashev, B. D. Kleshnin, "Technique of combining different views of radar video shots in a two-position system of on-board radars," T-Comm, 2026, vol. 20, no. 5, pp. 4-11. (in Russian)

1. Введение

В современном мире с каждым годом все чаще применяются малогабаритные бортовые радиолокационные системы (МБРЛС) с синтезированной апертурой, расположенные на борту малых летательных аппаратов (МЛА) для решения задач оперативного мониторинга в зонах чрезвычайной ситуации [1]. Такие системы позволяют осуществлять наблюдение земной поверхности в условиях, когда оптические системы подвержены погодными, атмосферными или световыми ограничениями.

Для оперативного мониторинга земной поверхности с помощью МБРЛС необходимо выполнение ряда требований: полнота получаемой информации; достоверность данных; скорость смены кадров за единицу времени; высокая точность пространственного положения объектов.

Выполнение этих требований необходимо для решения таких критически важных задач, как контроль состояния критической инфраструктуры, экологический контроль, оперативное обнаружение аварий на нефтепроводах, пожаров в лесах и проведение поисково-спасательных операций в условиях ограниченной видимости.

Существующие однопозиционные радиолокационные системы, установленные на МЛА, обладают ограничением, заключающимся в узкой зоне видимости за один пролет. Такие системы не всегда способны одновременно отвечать всем предъявляемым требованиям оперативного мониторинга. Это связано с необходимостью компромисса между детализацией получаемого снимка, шириной полосы захвата при наблюдении и временем, необходимым для полного обследования обширного района. Кроме того, однопозиционная система наблюдения приводит к образованию слепых зон, затененных участков и не позволяет осуществить перекрестную верификацию полученной информации.

Двухпозиционные пространственно-распределенные радиолокационные системы, способные формировать поток радиолокационных кадров (РЛК), получаемых с двух МЛА. Основное преимущество такого подхода заключается в возможности одновременного разноракурсного обзора большой территории. При этом видеопоток, формируемый каждой МБРЛС, обеспечивает высокую частоту смены кадров, а использование нескольких независимых ракурсов наблюдения позволяет повысить полноту и достоверность информации об объектах на земной поверхности. И как следствие, такой подход сокращает появление слепых зон и затененных участков [2].

Таким образом, цель настоящей работы заключается в исследовании и разработке методики совмещения разноракурсных радиолокационных видеок кадров, получаемых от пространственно-распределенной двухпозиционной радиолокационной систем, расположенных на малых летательных аппаратах.

2. Постановка задач

Для достижения поставленной цели требуется решить совокупность взаимосвязанных научно-технических задач:

- провести анализ методов и алгоритмов совмещения потока разноракурсных радиолокационных кадров;
- разработать методику совмещения разноракурсных радиолокационных видеопотоков;
- провести эксперимент совмещения разноракурсных радиолокационных видеок кадров на основе разработанной методики.

3. Двухпозиционная пространственно-распределённой радиолокационной система

Перед проведением анализа существующих алгоритмов и методов опишем двухпозиционную пространственно-распределённую МБРЛС.

На рисунке 1 представлена схема двухпозиционной пространственно-распределённой МБРЛС, в состав которой входят две независимые радиолокационные станции (РЛС) с синтезированной апертурой, установленные на борту отдельных малых летательных аппаратов [3].




Рис. 1. Схема двухпозиционной пространственно-распределённой радиолокационной системы

В результате работы системы формируются два независимых разноракурсных потока радиолокационных кадров, частично перекрывающихся в пределах общей зоны L' .

4. Анализ методов и алгоритмов совмещения потока разноракурсных радиолокационных кадров

При анализе методов и алгоритмов совмещения радиолокационных кадров необходимо учитывать ряд требований, обусловленных как ракурсом наблюдения, спецификой данных РЛК, и частотой смены кадров.

Обзор современных методов и алгоритмов совмещения потока РЛК показывает три основных группы (табл. 1).

Таблица 1

Группа методов и алгоритмов по совмещению разноракурсных радиолокационных видеок кадров

№	Общая группа	Алгоритмы и методы
1	Алгоритмы на основе локальных признаков	- SAR-SIFT; - OS-SIFT; - PSO-SIFT; - RIFT; - KAZE-SAR; - ININSC.
2	Нейросетевые дескрипторы (локальные признаки)	- LoFTR; - XoFTR; - RoMa, RoMaV2 и Tiny-RoMa; - SuperPoint; - SuperGlue; - LightGlue.
3	Методы геометрически ориентированного и устойчивого к деформациям совмещения много-ракурсных РЛК;	- HOLG (Histogram of Oriented Log-Gradients); - As-Projective-As-Possible; - SAR-BBS (Best-Buddy Similarity).

Во-первых, это методы на основе локальных признаков, адаптированных к свойствам РЛК. Во-вторых, нейросетевые дескрипторы, включая трансформеры и нейросети. В-третьих, геометрически ориентированные и устойчивые к деформациям подходы для многоракурсного.

Рассмотрим каждый метод и алгоритм подробнее:

Группа 1. Алгоритмы на основе локальных признаков

Алгоритм SAR-SIFT предназначен для поиска и сопоставления характерных точек на радиолокационных кадрах. В отличие от классического SIFT, он использует более устойчивые к радиолокационным данным признаки, например градиент отношения или фазовый градиент, что позволяет снизить влияние спекл-шума и перепадов интенсивности. Основное преимущество SAR-SIFT заключается в достаточно высокой точности совмещения РЛК, полученных при разных условиях съёмки и с разных ракурсов. К недостаткам относятся высокая вычислительная сложность и снижение эффективности на участках с малым числом выраженных деталей, а также в зонах радиолокационных теней и наложений [4].

Алгоритм OS-SIFT предназначен для совмещения оптических и радиолокационных изображений. Он формирует описание характерных точек с учётом различной природы получения данных, используя разные градиентные операторы для оптических и радиолокационных кадров. Основное преимущество OS-SIFT заключается в способности находить соответствия между изображениями, которые существенно отличаются по яркостной структуре и физическому принципу формирования. К недостаткам относится высокая вычислительная сложность построения признаков, что увеличивает время обработки и затрудняет применение алгоритма в потоковом режиме [5].

Алгоритм PSO-SIFT представляет собой модификацию алгоритма SIFT [6], в которой процесс сопоставления характерных точек дополняется оптимизационной процедурой. В рамках метода параметры преобразования между кадрами подбираются так, чтобы обеспечить наилучшее согласование найденных соответствий. Такой подход позволяет повысить устойчивость регистрации при нелинейных радиометрических различиях и неоднозначности сопоставлений. Преимуществом PSO-SIFT является возможность более надёжного поиска глобально согласованного преобразования. Однако использование дополнительной оптимизации резко увеличивает вычислительные затраты, поэтому алгоритм менее пригоден для обработки потока кадров в реальном времени.

Алгоритм RIFT основан на использовании фазовой информации, а не непосредственных значений яркости [7]. Ключевые точки в этом алгоритме определяются по устойчивым структурным признакам, а описание окрестности строится с использованием набора фильтров и карты максимальных откликов. Такой принцип делает RIFT устойчивым к различиям в яркости и контрасте, что особенно важно при сопоставлении изображений, полученных в разных условиях наблюдения. Достоинством метода является высокая устойчивость к РЛК. Недостатками являются повышенная вычислительная сложность и возможное снижение точности при сильных геометрических искажениях, когда локальная структура изображения заметно меняется между кадрами.

KAZE-SAR – это алгоритм совмещения РЛК, относящийся к группе алгоритмов на основе локальных признаков

[8]. Он использует детектор KAZE для поиска устойчивых характерных точек и модифицированный дескриптор SURF для их последующего сопоставления. Основная особенность KAZE-SAR заключается в построении нелинейного масштабного пространства, где вместо обычного гауссова сглаживания применяется нелинейная диффузионная фильтрация, которая уменьшает влияние спекл-шума, но при этом лучше сохраняет границы, контуры и другие важные структурные элементы РЛК.

Inertial Navigation Information and Neighborhood Structure Consensus (ININSC) использует не только изображение, но и априорную навигационную информацию [9]. Сначала в кадрах выделяются устойчивые объекты или области, затем с учётом данных инерциальной навигационной системы сокращается область поиска соответствий, после чего проверяется согласованность взаимного расположения соседних элементов. Такой подход особенно полезен при больших различиях углов наблюдения, когда чисто изобразительные признаки становятся недостаточно надёжными. Основное преимущество ININSC состоит в сочетании быстрей действия и устойчивости к разноракурсности. Ограничением метода является зависимость от качества навигационных данных, при наличии существенных ошибок в исходной оценке положения и ориентации точность сопоставления может снижаться.

Группа 2. Нейросетевые дескрипторы (локальные признаки)

К этой группе относятся методы и алгоритмы, в которых признаки изображения и правила их сопоставления формируются не вручную, а в результате обучения на больших наборах данных. В отличие от классических алгоритмов, такие подходы способны учитывать более сложные зависимости между фрагментами изображений и лучше работать в условиях геометрических искажений и различных условиях формирования РЛК. Для задач совмещения РЛК это особенно важно, поскольку один и тот же участок местности может иметь различный вид при изменении ракурса, дальности, угла места и условий формирования радиолокационного изображения.

Метод Local Feature TRansformer (LoFTR) выполняет сопоставление без предварительного выделения отдельных характерных точек [10]. Метод сравнивает изображения на нескольких уровнях детализации и устанавливает соответствия между их областями. Это позволяет находить связи даже там, где классические модели обнаружения признаков выделяют мало устойчивых точек. Достоинством LoFTR является высокая плотность и устойчивость сопоставлений. Недостаток заключается в высокой вычислительной нагрузке и необходимости обучения или настройки на данных, близких к радиолокационным.

Метод XoFTR является развитием LoFTR для изображений различной природы, в частности тепловизионными [11]. Его применение представляет интерес для случаев, когда требуется сопоставлять радиолокационные кадры с данными другого типа либо кадры РЛК, существенно различающиеся по характеру отображения местности. Основное преимущество метода состоит в повышенной устойчивости к различиям внешнего вида одних и тех же объектов. При этом для радиолокационных данных требуется специальная подготовка обучающих выборок, иначе качество сопоставления может быть нестабильным.

RoMa – обучаемый метод плотного сопоставления изображений, предназначенный для поиска большого числа соответствий между локальными областями. Он устойчив к изменениям масштаба, ракурса и внешнего вида сцены, поэтому может применяться при совмещении разноракурсных РЛК. Основной недостаток высокая вычислительная сложность.

RoMaV2 – усовершенствованная версия RoMa, обеспечивающая более точное и согласованное сопоставление при сложных геометрических изменениях. Метод лучше учитывает как общий контекст изображения, так и локальные деформации. Ограничением является повышенная требовательность к вычислительным ресурсам.

Tiny-RoMa – облегчённая версия RoMa, рассчитанная на работу при ограниченных вычислительных возможностях. Она обеспечивает компромисс между скоростью и точностью сопоставления, что важно для бортовых систем. Недостатком является возможное снижение точности при сильной разноракурсности и выраженных радиолокационных искажениях [12].

SuperPoint – нейросетевая модель выделения и описания характерных точек на изображении. В отличие от классических методов, где признаки задаются вручную, SuperPoint обучается автоматически и формирует как координаты ключевых точек, так и их дескрипторов. Модель включает два основных блока: первый отвечает за обнаружение ключевых точек, второй – за построение их численного дескриптора. Благодаря обучению на геометрически преобразованных изображениях SuperPoint сохраняет устойчивость к изменению масштаба, поворота, освещённости и локальной структуры сцены [13].

SuperGlue – нейросетевой алгоритм сопоставления ключевых точек, обычно применяемый совместно с SuperPoint. На вход SuperGlue подаются координаты точек и их дескриптор, после чего алгоритм устанавливает соответствия между двумя изображениями. Его особенность заключается в том, что при сопоставлении учитываются не только отдельные признаки, но и их взаимное расположение внутри каждого изображения, а также связи между двумя изображениями. Это позволяет уменьшить число ложных соответствий и повысить надёжность регистрации [14].

LightGlue – облегчённый алгоритм сопоставления признаков, разработанный как более быстрый и менее требовательный к вычислительным ресурсам вариант SuperGlue. Его основная особенность состоит в адаптивной глубине обработки: если соответствия между изображениями находятся достаточно уверенно, вычисления завершаются раньше, а для более сложных пар кадров используется дополнительная обработка. Такой механизм позволяет сократить время работы без существенной потери точности. Алгоритм LightGlue применяется в задачах, где требуется высокая скорость обработки видеопотока, близком к реальному времени [15].

В целом нейросетевые методы обладают высокой точностью и хорошо работают при сложных изменениях изображений. Однако их применение в бортовых РЛС требует достаточное аппаратно-вычислительное обеспечение, необходимое для предварительного обучения и совмещения разноракурсных РЛК.

Группа 3. Геометрически ориентированные и устойчивые к деформациям методы многоракурсного совмещения

Эта группа методов предназначена для случаев, когда

кадры получены с существенно разных направлений наблюдения и не могут быть надёжно совмещены только с помощью простых преобразований. При многоракурсной радиолокационной съёмке одни и те же объекты могут иметь различную форму, яркость и взаимное расположение в кадре. Поэтому такие методы сочетают устойчивые признаки изображения с более сложными геометрическими моделями.

Histogram of oriented log gradient (HOLG) использует распределение ориентированных логарифмических градиентов, что позволяет учитывать характерные особенности РЛК, включая спекл-шум, искажения и резкие перепады яркости. Метод формирует более устойчивое описание локальной структуры кадра и может применяться при больших углах ракурса. Его достоинством является повышенная устойчивость к шуму и локальным изменениям изображения. Недостатком является зависимость от качества выделения градиентной структуры: на однородных участках и в областях радиолокационных теней информативность признаков снижается [16].

As-Projective-As-Possible относится к методам геометрического преобразования, в которых изображение выравнивается не одной общей моделью, а набором локально согласованных преобразований. Это позволяет учитывать нелинейные деформации, возникающие при разных углах наблюдения, изменении высоты съёмки и сложной форме рельефа. Преимущество метода заключается в способности совмещать изображения при сильных геометрических расхождениях. Недостаток состоит в риске локальных искажений при недостаточном числе надёжных соответствий или при их неравномерном распределении по кадру [17].

SAR-BBS использует идею взаимно наилучших соответствий между фрагментами РЛК. Сначала определяется приближённая область поиска, затем выполняется уточнение соответствий с использованием меры взаимного сходства и радиолокационно-ориентированной обработки границ. Такой подход позволяет устойчиво сопоставлять изображения при поворотах, сдвигах и заметных различиях локальной структуры. Его достоинством является робастность к ложным совпадениям и шуму. Ограничением является повышенная вычислительная сложность, поскольку требуется выполнять поиск по локальным областям и оценивать взаимное сходство фрагментов [18].

В результате проведённого анализа можно выделить следующее: задачи совмещения разноракурсных радиолокационных видеок кадров в двухпозиционной системе МБРЛС наиболее подходящим является подход, сочетающий устойчивое выделение и сопоставление локальных признаков, использование априорной навигационной информации, геометрическое моделирование преобразования между кадрами и временную стабилизацию параметров совмещения. Классические алгоритмы на основе локальных признаков, такие как SAR-SIFT, RIFT, KAZE-SAR и ININSC, обладают высокой устойчивостью к ряду радиометрических искажений, однако могут быть недостаточно эффективны при сильной разноракурсности, радиолокационных тенях и низкой информативности отдельных участков. Нейросетевые методы обеспечивают более высокую устойчивость к сложным изменениям структуры изображения, но требуют значительных вычислительных ресурсов и предварительной адаптации к данным конкретной РЛС. Наиболее целесообразным для дальнейшей

разработки методики является использование LoFTR, поскольку данный метод выполняет сопоставление без предварительного выделения отдельных характерных точек и способен устанавливать соответствия между областями изображений даже при недостатке устойчивых локальных признаков. Геометрически ориентированные методы, такие как As-Projective-As-Possible, могут применяться на последующих этапах для уточнения преобразования между кадрами и компенсации нелинейных деформаций, возникающих при много-ракурсном наблюдении.

5. Методика совмещения разноракурсных радиолокационных видеок кадров, сформированных на базе малогабаритной бортовой радиолокационной системы

Предлагаемая методика (рис. 2) предназначена для совмещения двух независимых разноракурсных потоков радиолокационных кадров, формируемых МБРЛС, размещёнными на борту двух МЛА. В качестве входных данных используются сами РЛК, а также метаданные спутниковой навигации GPS/ГЛОНАСС и инерциальной навигационной системы, содержащие сведения о положении, ориентации и движении носителей. Эти данные применяются для предварительной геометрической привязки кадров и сокращения области поиска соответствий.

Предлагаемая методика состоит из следующих шагов:

Шаг 1. Получение входных данных.

На первом этапе в систему поступают два независимых радиолокационных видеопотока, формируемых МБРЛС, расположенными на борту двух МЛА. Одновременно для каждого кадра принимаются метаданные спутниковой навигации GPS/ГЛОНАСС и инерциальной навигационной системы. К ним относятся координаты носителя, высота, скорость, углы ориентации и временная метка. Эти данные используются для приблизительной геопривязки кадров, оценки положения носителей и определения возможной зоны перекрытия двух видеопотоков.

Шаг 2. Подготовка радиолокационных кадров к обработке.

Полученные кадры приводятся к единому формату представления. Выполняется нормализация яркостных значений, необходимая для уменьшения влияния различий в радиометрических характеристиках изображений, полученных с разных ракурсов. При необходимости дополнительно выполняется подавление шумовых составляющих, характерных для РЛК. На выходе данного этапа формируются пары кадров, пригодные для последующего поиска соответствий [19].

Шаг 3. Предварительная геометрическая привязка.

На основе данных GPS/ГЛОНАСС и ИНС выполняется приближённая оценка взаимного положения кадров в общей системе координат. Это позволяет определить область возможного перекрытия двух радиолокационных видеопотоков и сократить область поиска соответствующих фрагментов. Данный этап особенно важен, поскольку два МЛА движутся по неидеальным траекториям, а кадры формируются с разных направлений наблюдения и могут иметь различный масштаб, поворот и процент перекрытия.

Шаг 4. Извлечение признаков методом LoFTR.

В результате проведённого анализа для сопоставления разноракурсных радиолокационных кадров выбран метод LoFTR. На данном этапе каждый кадр разбивается на сетку перекрывающихся блоков размером 16×16 пикселей с шагом 8 пикселей. Для каждого блока вычисляются градиенты яркости по осям X и Y с использованием оператора Собеля. Это позволяет выделить контуры, перепады яркости и текстурные области, которые могут быть использованы для поиска соответствий между кадрами.

Шаг 5. Формирование локальных дескрипторов.

Для каждого блока формируется численное описание локальной области изображения. В единый дескриптор объединяются значения исходной яркости, горизонтального градиента и вертикального градиента. В результате формируется дескриптор размерностью 768 элементов: 256 значений яркости, 256 значений градиента по оси X и 256 значений градиента по оси Y. Далее каждый дескриптор нормализуется по L2-норме, что повышает устойчивость сопоставления к изменению яркости и контраста между кадрами.




Рис. 2. Схема, описывающая методику совмещения РЛ-кадров

Шаг 6. Формирование контекстных дескрипторов.

Для учёта пространственного окружения каждой точки используется контекстное описание. Для позиции (x, y) на карте признаков извлекаются векторы из окрестности 3×3 , после чего они объединяются в единый дескриптор размером 6912 элементов. Такой подход позволяет учитывать не только отдельную локальную область, но и её ближайшее окружение. Это повышает устойчивость сопоставления при разноракурсном наблюдении, когда форма и яркость одних и тех же объектов могут изменяться.

Шаг 7. Отбор информативных точек.

После построения дескрипторов выполняется адаптивный отбор наиболее информативных областей. Для каждого дескриптора вычисляется дисперсия, которая используется как мера текстурной сложности. Области с высокой дисперсией, соответствующие углам, резким перепадам яркости, границам объектов и сложным текстурам, выбираются как наиболее перспективные для сопоставления. В рамках методики отбираются от 40 до 400 наиболее информативных точек, что обеспечивает баланс между точностью совмещения и вычислительной эффективностью.

Шаг 8. Сопоставление кадров двух видеопотоков.

Для каждой выбранной точки первого кадра вычисляется косинусное расстояние до всех выбранных точек второго кадра (рис. 3). Данная мера позволяет оценить близость дескрипторов в многомерном пространстве признаков и снижает влияние различий яркости и контраста. Далее выполняется взаимная проверка соответствий: пара точек считается корректной только в том случае, если каждая из них является наилучшим соответствием для другой. Это позволяет уменьшить количество ложных совпадений.




Рис. 3. Результат обнаружения и сопоставления точек

Шаг 9. Фильтрация соответствий и построение матрицы расстояний.

На следующем этапе выполняется фильтрация найденных соответствий по пороговому значению косинусного расстояния. В рамках предлагаемой реализации используется порог 0,4, выбранный для обеспечения баланса между точностью и полнотой сопоставления. Соответствия, не удовлетворяющие данному условию, исключаются из дальнейшей обработки. После этого строится матрица попарных расстояний между кадрами двух видеопотоков, что позволяет оценить качество

сопоставления, выявить наиболее близкие пары кадров и обнаружить возможные систематические ошибки.

Шаг 10. Оценка преобразования и формирование совмещенного РЛ кадра.

По отфильтрованным соответствиям оценивается геометрическое преобразование, необходимое для приведения одного кадра к системе координат другого [20]. Далее выполняется совмещение перекрывающихся областей двух радиолокационных видеопотоков и формируется совмещенный радиолокационный кадр (рис. 4).



Рис. 4. Результат совмещения разноракурсного РЛК

Полученный результат объединяет информацию, поступающую с двух независимых ракурсов, что позволяет повысить полноту наблюдения, уменьшить влияние затенённых участков и обеспечить более достоверное представление наблюдаемой территории. Для дополнительной проверки работоспособности предложенной методики был рассмотрен ещё один случай совмещения разноракурсных радиолокационных кадров (рис. 5-7).



Рис. 5. Два разноракурсных РЛ кадров



Рис. 6. Сопоставление разноракурсных кадров



Рис. 7. Сопоставление разноракурсных кадров

Представленные результаты показывают, что предложенная методика позволяет находить устойчивые соответствия между разноракурсными радиолокационными кадрами и выполнять их последующее геометрическое совмещение. Наличие согласованных пар точек подтверждает корректность работы этапа сопоставления, а формирование совмещённого кадра демонстрирует возможность объединения данных, полученных с разных направлений наблюдения. Это подтверждает применимость разработанной методики для обработки радиолокационных видеопотоков в двухпозиционной системе МБРЛС.

Заключение

В работе рассмотрена задача совмещения разноракурсных радиолокационных видеок кадров, формируемых двухпозиционной пространственно-распределённой системой МБРЛС, размещённой на борту малых летательных аппаратов.

Проведён анализ современных методов и алгоритмов совмещения радиолокационных кадров. Рассмотрены алгоритмы на основе локальных признаков (SAR-SIFT, OS-SIFT, PSO-SIFT, RIFT, KAZE-SAR и ININSC), нейросетевые методы сопоставления (LoFTR, XoFTR и семейство моделей RoMa) и геометрически ориентированные подходы (HOLG, As-Projective-As-Possible, SAR-BBS).

Для разработки методики выбран метод LoFTR, поскольку он позволяет выполнять сопоставление кадров без предварительного выделения отдельных ключевых точек и находить соответствия между областями изображений. Это повышает устойчивость совмещения при изменении ракурса, масштаба и яркостной структуры радиолокационного кадра.

Предложенная методика включает получение двух радиолокационных видеопотоков и навигационных данных GPS/ГЛОНАСС и ИНС, предварительную геометрическую привязку, подготовку кадров, извлечение и сопоставление признаков, фильтрацию соответствий, оценку геометрического преобразования и формирование совмещённого радиолокационного кадра. Результаты проверки показали, что методика позволяет совмещать разноракурсные радиолокационные кадры.

Литература

1. Ненашев В.А., Ненашев С.А. Классификация и распознавание наземных объектов в потоке радиолокационных кадров на основе нейросетевого подхода // Труды Международной конференции по компьютерной графике и зрению" Графикон. 2023. № 33. С. 572-580.
2. Wen L., Ding J., Loffeld O. Video SAR moving target detection using dual faster R-CNN // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2021. Т. 14. С. 2984-2994.
3. Бабочкин М.И., Савостьянов В.Ю. Выбор оптимальной частоты повторения импульсов в PCA с телескопическим обзором поверхности // Ural Radio Engineering Journal. 2024. Т. 8. № 4. С. 438-450.
4. Wang M. et al. Combining optimized SAR-SIFT features and RD model for multisource SAR image registration // IEEE Transactions on Geoscience and Remote Sensing. 2021. Т. 60. С. 1-16.
5. Zhang X., Wang Y., Liu H. Robust optical and SAR image registration based on OS-SIFT and cascaded sample consensus // IEEE Geoscience and Remote Sensing Letters. 2021. Т. 19. С. 1-5.
6. Pang S. et al. RTV-SIFT: Harnessing structure information for robust optical and SAR image registration // Remote Sensing. 2023. Т. 15. № 18. С. 4476.
7. Тонких А.Н. Применение нейросетевых технологий для распознавания распределённых объектов на радиолокационных изображениях // Труды МАИ. 2025. № 141. С. 14.
8. Pourfard M. et al. KAZE-SAR: SAR image registration using KAZE detector and modified SURF descriptor for tackling speckle noise // IEEE Transactions on Geoscience and Remote Sensing. 2021. Т. 60. С. 1-12.
9. Yan H. et al. A Fast Matching Method for the SAR Images with Large Viewing Angles Based on Inertial Navigation Information and Neighborhood Structure Consensus // Remote Sensing. 2023. Т. 15. № 16. С. 4084.
10. Sun J. et al. LoFTR: Detector-free local feature matching with transformers // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021. С. 8922-8931.
11. Борисов А.Н., Мясников В.В., Сергеев В.В. Метод автоматического совмещения разнородных цифровых изображений дистанционного зондирования Земли // Компьютерная оптика. 2024. Т. 48. № 6. С. 932-943.
12. Corley I., Stoken A., Berton G. Are Pretrained Image Matchers Good Enough for SAR-Optical Satellite Registration? //arXiv preprint arXiv:2604.10217. 2026.
13. Hui L. et al. Superpoint network for point cloud oversegmentation // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021. С. 5510-5519.
14. Li Y. et al. Application and implementation of SuperGlue algorithm based on deep learning in image stitching // Proceedings of the 2025 6th International Conference on Computer Information and Big Data Applications. 2025. С. 172-177.
15. Lindenberger P., Sarlin P.E., Pollefeys M. Lightglue: Local feature matching at light speed // Proceedings of the IEEE/CVF international conference on computer vision. 2023. С. 17627-17638.
16. Xiong X. et al. Robust multi-view UAV SAR image registration based on selective correlation of log gradient descriptor // International Journal of Applied Earth Observation and Geoinformation. 2024. Т. 127. С. 103678.
17. Zhu C. et al. Fast multiscale SAR images stitching based on improved APAP and OTSU algorithms // IET Conference Proceedings CP874. Stevenage, UK: The Institution of Engineering and Technology, 2023. Т. 2023. № 47. С. 2845-2852.
18. Zhang Y. et al. A robust registration method for multi-view SAR images based on best buddy similarity // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2024. Т. 48. С. 881-886.
19. Ненашев В.А., Ненашев С.А., Бестугин А.Р. и др. Контроль наземных объектов на основе нейросетевого распознавания в авиационных системах технического зрения // Датчики и системы. 2024. № 2(274). С. 57-61
20. Константинов И.С., Гайворонский В.А. Формирование данных о пространстве многокамерными видеосистемами // Экономика. Информатика. 2022. Т. 49. № 4. С. 863-870.

TECHNIQUE OF COMBINING DIFFERENT VIEWS OF RADAR VIDEO SHOTS IN A TWO-POSITION SYSTEM OF ON-BOARD RADARS

Vadim A. Nenashev, SUAI, Saint Petersburg, Russia, nenashev.va@yandex.ru, nenashev@guap.ru

Sergey A. Nenashev, SUAI, Saint Petersburg, Russia, nenashev_sergey178@mail.ru

Boris D. Kleshnin, SUAI, Saint Petersburg, Russia, boria456@gmail.com

The study was funded by the Russian Science Foundation, project No. 24-79-10259

Abstract

In the tasks of operational monitoring of the earth's surface using small-sized airborne radar systems mounted on small aircraft, it becomes necessary to form a single combined frame based on two different-angle radar video streams. The main difficulty lies in the presence of radar shadows, geometric distortions and incomplete overlap of frames, which makes it difficult to accurately combine them and subsequent analysis. The aim of the work is to study and develop a technique for combining multi-angle radar video frames generated by a two-position spatially distributed small-sized airborne radar system to obtain a single radar frame. The paper analyzes modern methods and algorithms for combining radar images, including algorithms based on local features, neural network matching methods and geometrically oriented approaches. Based on the results of the analysis, the LoFTR method was chosen for the main matching procedure, which provides a dense search for correspondences between image areas without pre-selecting individual characteristic points. The proposed methodology includes the use of GPS/GLONASS and inertial navigation system data for preliminary geometric anchoring, preparation of radar frames, extraction and comparison of features, filtering of false correspondences, evaluation of geometric transformations and the formation of a single panorama. A technique for combining two different-angle radar video streams is proposed. The use of LoFTR increases the stability of the comparison in case of angle changes, differences in the radiometric structure of frames and a lack of pronounced local features. The results obtained show the possibility of forming a single radar frame based on data received from two independent radar stations. The proposed methodology can be used in the tasks of operational monitoring of the Earth's surface, control of critical infrastructure, environmental monitoring, emergency detection and search and rescue operations.

Keywords: radar image fusion, multi-angle video streams, panoramic scene, LoFTR, small-sized radar, Jetson Nano, real-time monitoring.

References

- [1] V. A. Nenashev, S. A. Nenashev, "Classification and recognition of ground objects in the radar frame stream based on a neural network approach," *Proceedings of the International Conference on Computer Graphics and Vision Graphicon*. 2023, no. 33, pp. 572-580.
- [2] L. Wen, J. Ding, O. Löffel, "Video SAR moving target detection using dual faster R-CNN," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. Vol. 14, pp. 2984-2994.
- [3] M. I. Babokin, V. Yu. Savostyanov, "Choosing the optimal pulse repetition frequency in a radar with a telescopic surface view," *Ural Radio Engineering Journal*. 2024. Vol. 8. No. 4, pp. 438-450.
- [4] M. Wang et al., "Combining optimized SAR-SIFT features and RD model for multisource SAR image registration," *IEEE Transactions on Geoscience and Remote Sensing*. 2021. Vol. 60, pp. 1-16.
- [5] X. Zhang, Y. Wang, H. Liu, "Robust optical and SAR image registration based on OS-SIFT and cascaded sample consensus," *IEEE Geoscience and Remote Sensing Letters*. 2021. Vol. 19, pp. 1-5.
- [6] S. Pang et al., "RTV-SIFT: Harnessing structure information for robust optical and SAR image registration," *Remote Sensing*. 2023. Vol. 15. No. 18. P. 4476.
- [7] A. N. Tonkikh, "Application of neural network technologies for recognition of distributed objects in radar images," *Proceedings of the MAI*. 2025. No. 141. P. 14.
- [8] M. Pourfard et al., "KAZE-SAR: SAR image registration using KAZE detector and modified SURF descriptor for tackling speckle noise," *IEEE Transactions on Geoscience and Remote Sensing*. 2021. Vol. 60. P. 1-12.
- [9] H. Yan et al., "A Fast Matching Method for the SAR Images with Large Viewing Angles Based on Inertial Navigation Information and Neighborhood Structure Consensus," *Remote Sensing*. 2023. Vol. 15. No. 16. P. 4084.
- [10] J. Sun et al., "LoFTR: Detector-free local feature matching with transformers," *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2021, pp. 8922-8931.
- [11] A. N. Borisov, V. V. Myasnikov, V. V. Sergeev, "Method of automatic combination of heterogeneous digital images of remote sensing of the Earth," *Computer optics*. 2024. Vol. 48. No. 6, pp. 932-943.
- [12] I. Corley, A. Stoken, G. Berton, "Are Pretrained Image Matchers Good Enough for SAR-Optical Satellite Registration?" arXiv preprint arXiv:2604.10217. 2026.
- [13] L. Hui et al., "Superpoint network for point cloud oversegmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021, pp. 5510-5519.
- [14] Y. Li et al., "Application and implementation of SuperGlue algorithm based on deep learning in image stitching," *Proceedings of the 2025 6th International Conference on Computer Information and Big Data Applications*. 2025, pp. 172-177.
- [15] P. Lindenberger, P. E. Sarlin, M. Pollefeys, "Lightglue: Local feature matching at light speed," *Proceedings of the IEEE/CVF international conference on computer vision*. 2023, pp. 17627-17638.
- [16] X. Xiong et al., "Robust multi-view UAV SAR image registration based on selective correlation of log gradient descriptor," *International Journal of Applied Earth Observation and Geoinformation*. 2024. Vol. 127. P. 103678.
- [17] C. Zhu et al., "Fast multiscale SAR images stitching based on improved APAP and OTSU algorithms," *IET Conference Proceedings CP874*. Stevenage, UK: The Institution of Engineering and Technology, 2023. Vol. 2023. No. 47, pp. 2845-2852.
- [18] Y. Zhang et al., "A robust registration method for multi-view SAR images based on best buddy similarity," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2024. Vol. 48, pp. 881-886.
- [19] V. A. Nenashev, S. A. Nenashev, A. R. Bestugin et al., "Control of ground objects based on neural network recognition in aviation vision systems," *Sensors and systems*. 2024. No. 2(274), pp. 57-61.
- [20] I. S. Konstantinov, V. A. Gaivoronskiy, "Formation of spatial data by multi-camera video systems," *Economy. Computer science*. 2022. Vol. 49. No. 4, pp. 863-870.

Information about authors:

Vadim A. Nenashev, Doctor of Technical Sciences, Head of the machine learning laboratory of the SUAI engineering school, associate professor of the department of "Design and technology of electronic and laser devices" of SUAI, Saint Petersburg, Russia

Sergey A. Nenashev, Head of the Industrial Electronics Laboratory of the Design and Technology Office of the Engineering School of SUAI, Junior Researcher at the Department of Design and Technology of Electronic and Laser Equipment at SUAI, Postgraduate Student at SUAI, Saint Petersburg, Russia

Boris D. Kleshnin, Is an engineer at the Industrial Electronics Laboratory of the Engineering School's Design and Technology Office, a student at the Department of Design and Technology of Electronic and Laser Devices, and a master's student at SUAI, Saint Petersburg, Russia

ОЦЕНКА ТОЧНОСТИ UWB-ДАЛЬНОМЕТРИИ ДЛЯ ПОЗИЦИОНИРОВАНИЯ КАРЬЕРНОЙ ТЕХНИКИ В СЛОЖНОЙ РАДИОСРЕДЕ

Смирнов Петр Ильич,

Вологодский государственный университет, Вологда, Россия,
smirnovpi@vogu35.ru

Валяев Олег Алексеевич,

Московский автомобильно-дорожный государственный технический университет (МАДИ), Москва, Россия, o.valyaev@madi.ru

Баурова Наталья Ивановна,

Московский автомобильно-дорожный государственный технический университет (МАДИ), Москва, Россия, nbaurova@mail.ru

Мазлумян Григорий Сергеевич,

Московский автомобильно-дорожный государственный технический университет (МАДИ), Москва, Россия, g.mazlumyan@madi.ru

Субботин Борис Сергеевич,

Московский автомобильно-дорожный государственный технический университет (МАДИ);
ФГБОУ ВО "РГУ им. А.Н. Косыгина", Москва, Россия, bsubbotin@mail.ru

DOI: 10.36724/2072-8735-2026-20-5-12-21

Manuscript received 08 February 2026;

Accepted 17 April 2026

Ключевые слова: ультра-широкополосная радиосвязь (UWB), радиодальнометрия, позиционирование, карьерная техника, NLOS, многолучевость, погрешность измерения, геометрический фактор

В условиях горных карьеров задачи высокоточного позиционирования карьерной техники осложняются сложной геометрией выработки, наличием высоких уступов, металлических конструкций и интенсивной многолучевостью, приводящих к эффектам NLOS и существенным погрешностям радиодальнометрии. В работе рассматривается применение ультра-широкополосной технологии UWB для позиционирования подвижных машин в карьере и предлагается стохастическая модель ошибки дальнометрии, учитывающая вклад NLOS смещения, многолучевого распространения и геометрического фактора конфигурации опорных точек. На основе имитационного моделирования анализируется распределение координатной ошибки в типичных сценариях карьерной радиосреды (LOS, частичный и полный NLOS) при благоприятной и неблагоприятной геометрии размещения UWB опорных станций. Показано, что в условиях прямой видимости при благоприятной геометрии анкерных станций средняя ошибка позиционирования составляет около 0.07 м, RMSE – 0.09 м, а 95 й процентиль не превышает 0.17 м, тогда как при полном NLOS и неблагоприятной геометрии RMSE возрастает до 12.84 м. Применение простой робастной обработки дальномерных измерений с ограничением выбросов по порогу 5 м позволяет уменьшить RMSE в этом сценарии до 4.97 м, существенно снижая влияние грубых аномалий при сохранении точности в LOS условиях. Практическая значимость работы заключается в формировании рекомендаций по размещению базовых UWB станций и настройке алгоритмов обработки измерений, обеспечивающих требуемую точность мониторинга движения карьерной техники в сложной радиосреде.

Информация об авторах:

Смирнов Петр Ильич, Вологодский государственный университет, Институт машиностроения, энергетики и транспорта, кафедра "Автомобили и автомобильное хозяйство", доцент, к.т.н., Вологда, Россия. ORCID 0000-0002-9405-7248

Валяев Олег Алексеевич, Московский автомобильно-дорожный государственный технический университет (МАДИ), Институт автомобильной и специальной техники и инжиниринга, кафедра "Транспортные установки", старший преподаватель, Москва, Россия, ORCID 0009-0000-1025-8388

Баурова Наталья Ивановна, Московский автомобильно-дорожный государственный технический университет (МАДИ), Институт автомобильной и специальной техники и инжиниринга, кафедра "Производство и ремонт автомобилей и дорожно-строительных машин", профессор, д.т.н., Москва, Россия. ORCID 0000-0001-9529-2031

Мазлумян Григорий Сергеевич, Московский автомобильно-дорожный государственный технический университет (МАДИ), проректор по научной работе, к.т.н., Москва, Россия. ORCID 0009-0001-9296-0775

Субботин Борис Сергеевич, Московский автомобильно-дорожный государственный технический университет (МАДИ), старший научный сотрудник, к.т.н.; РГУ им. А.Н. Косыгина, доцент, к.т.н., Москва, Россия, ORCID 0000-0003-1685-082X

Для цитирования:

Смирнов П.И., Валяев О.А., Баурова Н.И., Мазлумян Г.С., Субботин Б.С. Оценка точности UWB-дальнометрии для позиционирования карьерной техники в сложной радиосреде // Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 12-21.

For citation:

P.I. Smirnov, O.A. Valyaev, N.I. Baurova, G.S. Mazlumyan, B.S. Subbotin, "Assessment of UWB Ranging Accuracy for Positioning Mining Trucks in a Complex Radio Environment," T-Comm, 2026, vol. 20, no.5, pp. 12-21. (in Russian)

Введение

Позиционирование подвижных объектов в горных выработках остаётся одной из ключевых задач цифровизации промышленного транспорта, поскольку эффективность диспетчеризации, контроль движения техники и обеспечение безопасности напрямую зависят от точности координатной информации. В условиях карьеров и подземных выработок система локализации должна функционировать в сложной и нестационарной радиосреде, где на распространение сигнала одновременно влияют высокие уступы, отвалы, технологическое оборудование, крупногабаритная техника и постоянное изменение конфигурации рабочей зоны.

В отличие от открытых пространств, карьер и шахта характеризуются выраженной многолучевостью, частой потерей прямой видимости и сильной зависимостью качества радиоканала от геометрии выработки. Эти факторы приводят к росту ошибки дальнометрии и существенно ограничивают применение спутниковой навигации как единственного источника координатной информации. Поэтому в последние годы повышенное внимание уделяется локальным радиотехническим системам позиционирования, основанным на измерении времени прихода или времени пролёта сигнала между опорными станциями и подвижным объектом.

Одним из наиболее перспективных направлений в этой области являются технологии Wi-Fi FTM/RTT и UWB, которые обеспечивают метр- и субметровую точность при благоприятных условиях распространения и при этом не требуют спутникового сигнала. Для Wi-Fi FTM показано, что точность измерения существенно зависит от ширины канала, калибровки смещения, уровня помех и многолучевого распространения [1, 7, 8], а в условиях NLOS погрешность заметно возрастает [2, 10, 11]. UWB-системы обладают более высокой временной разрешающей способностью и потому особенно интересны для сложных промышленных сценариев, включая шахты и подземные выработки [3, 4].

Вместе с тем высокая точность UWB в лабораторных и indoor-сценариях не гарантирует аналогичного результата в карьерах, где NLOS и многолучевое распространение возникают систематически и часто сопровождаются неблагоприятной геометрией расположения базовых станций. Для таких условий были предложены методы компенсации NLOS-ошибок, основанные на классификации типа канала, адаптивной фильтрации и расширенном фильтре Калмана [6], однако большинство из них ориентировано на типовые indoor-среды или подземные тоннели и не учитывает специфику открытых горных выработок. Кроме того, развитие методов на основе картирования канала, скрытых марковских моделей и мультимодального обучения [13, 14] показывает, что современные подходы к локализации всё чаще переходят от простой геометрии к учёту структуры канала и его временной изменчивости. Отдельного внимания заслуживают работы по совместной оценке времени прихода в многолучевых каналах [12], а также новые стандарты, такие как IEEE 802.11az с использованием миллиметрового диапазона [5] и вопросы безопасности дальнометрии [15].

В работе [16] показано, что в условиях ограниченной видимости интеграция UWB с IMU и применение улучшенного ESKF существенно снижают ошибку позиционирования по сравнению с чистым UWB, что подтверждает необходимость робастной обработки измерений в NLOS-сценариях.

Несмотря на значительное число работ, посвящённых UWB-локализации в indoor- и подземных сценариях, большинство из них рассматривает сравнительно компактные геометрии, ограниченные диапазоны расстояний до опорных станций и умеренные уровни NLOS-искажений. В частности, опубликованные модели компенсации NLOS-ошибок, как правило, ориентированы на помещения, тоннели или шахтные выработки и не учитывают сочетание большой протяжённости рабочей зоны, выраженной высотной неоднородности и быстро меняющейся геометрии карьера. В настоящей работе это ограничение преодолевается за счёт явной параметризации карьерной радиосреды через DOP-подобный фактор, диапазон расстояний до анкерных точек и логнормальную модель NLOS-смещения, а также за счёт анализа устойчивости координатной оценки при 5000 прогонов для каждого сценария.

Актуальность настоящего исследования определяется необходимостью оценки точности UWB-дальнометрии именно в условиях карьерной среды, где прямое перенесение indoor-моделей приводит к недооценке погрешностей и к ошибкам при проектировании системы позиционирования. В работе используется имитационный подход, позволяющий в контролируемых условиях варьировать параметры карьерной радиосреды, уровень NLOS и геометрический фактор расположения опорных станций.

Целью настоящей работы является имитационная оценка точности UWB-дальнометрии для позиционирования карьерной техники в сложной радиосреде с учётом влияния NLOS, многолучевости и геометрического фактора расположения опорных станций.

Научная новизна работы заключается в следующем:

1. Предложена и исследована имитационная модель UWB-позиционирования, ориентированная на карьерную радиосреду с учётом больших дальностей, неблагоприятной геометрии анкерных станций и систематических NLOS-искажений.
2. Выполнен анализ чувствительности координатной ошибки к изменению геометрии анкерной сети и доли NLOS-сценариев, что позволяет количественно оценить условия деградации точности в карьерных условиях.
3. Показано, что даже простая робастная обработка дальномерных измерений существенно уменьшает влияние грубых выбросов в сложной радиосреде, что подтверждает целесообразность предварительной фильтрации измерений при позиционировании карьерной техники.

1. Особенности радиосреды карьера

Радиосреда карьера формируется совокупностью факторов, существенно усложняющих распространение сигнала между опорными станциями и подвижной техникой. В первую очередь это высокая вероятность экранирования пря-

мого луча уступами, отвальными массивами, технологическими сооружениями и крупногабаритными машинами. Кроме того, поверхность уступов, стенок выработки и металлических конструкций создает многочисленные отраженные пути, которые накладываются на полезный сигнал и приводят к многолучевому распространению.

Для карьерной среды характерна не только сильная многолучевость, но и выраженная нестационарность канала. По мере продвижения фронта работ меняются геометрия выработки, взаимное расположение техники и опорных станций, а также условия видимости. Это означает, что один и тот же маршрут может в разные моменты времени соответствовать различным типам радиоканала: от устойчивого LOS до частичного или полного NLOS. Следовательно, система позиционирования должна быть чувствительна к изменению канальных условий и сохранять работоспособность в широком диапазоне сценариев.

С точки зрения радиотехнического анализа целесообразно выделить несколько типовых режимов распространения сигнала в карьере. Первый режим – LOS, при котором между меткой и опорной станцией существует прямая видимость, а основная ошибка измерения определяется шумом и остаточным влиянием отражений. Второй режим – частичный NLOS, когда прямой путь существует, но ослаблен или искажен отраженными компонентами. Третий режим – полный NLOS, при котором измерение формируется исключительно за счет отраженных путей и может содержать существенное систематическое смещение [6-8].

Наиболее критичным для UWB-дальнометрии является именно полный NLOS, поскольку в этом случае оценка времени прихода первого сигнала становится неопределенной, а измеренная дальность возрастает по сравнению с истинной. В сочетании с неблагоприятной геометрией опорных станций это приводит к заметному росту координатной ошибки, особенно если базовые станции расположены слабо симметрично относительно рабочей зоны техники. Таким образом, точность позиционирования определяется не только свойствами самого радиосигнала, но и пространственной организацией всей измерительной системы.

Еще одной особенностью карьера является большая протяженность рабочих зон. В отличие от помещений, где расстояния между узлами невелики и геометрия достаточно компактна, в карьере опорные станции могут находиться на значительном удалении друг от друга и от объекта позиционирования. Это усиливает роль геометрического фактора и делает ошибку особенно чувствительной к расположению анкерных точек. Поэтому при проектировании системы UWB-позиционирования необходимо учитывать не только точность оборудования, но и структуру рабочей зоны, рельеф, высотные отметки и потенциальные экранирующие объекты.

Для дальнейшего анализа целесообразно использовать модель, в которой измеренная дальность представляется суммой истинной дальности и нескольких составляющих ошибки: систематического NLOS-смещения, вклада многолучевости и случайной шумовой компоненты. Такая постановка позволяет исследовать влияние каждого фактора отдельно и затем оценить их совместное действие на координатную точность [6-9].

2. Модель UWB-дальнометрии и ошибки

В основу рассматриваемого подхода положена модель измерения расстояния между подвижной меткой и i -й опорной станцией, в которой измеренная дальность представляется как сумма истинной дальности и нескольких составляющих ошибки. Для UWB-систем в условиях карьера наибольший вклад в погрешность вносят NLOS-смещение, многолучевое распространение и случайная шумовая составляющая.

Пусть истинная дальность до i -й опорной станции равна d_i , а измеренное значение обозначим через r_i . Тогда модель измерения может быть записана в виде (1):

$$r_i = d_i + b_i + m_i + n_i, \quad (1)$$

где b_i – систематическое смещение, вызванное отсутствием прямой видимости (NLOS),

m_i – ошибка, связанная с многолучевым распространением,

n_i – случайная шумовая составляющая.

В имитационной модели NLOS-смещение b_i задается логнормальным распределением, поскольку оно гарантирует положительность ошибки дальности и позволяет воспроизводить редкие, но крупные превышения измеренного расстояния над истинным значением.

Истинная дальность выражается через координаты подвижного объекта $p = (x, y, z)^T$ и координаты i -й опорной станции $p_i = (x_i, y_i, z_i)^T$ следующим образом (2):

$$d_i = \|p - p_i\| = \sqrt{(x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2}, \quad (2)$$

В LOS-условиях величины b_i близки к нулю, а ошибка определяется в основном шумом и остаточным влиянием отражений. В NLOS-режиме смещение b_i , напротив, становится положительным и приводит к завышению оценки дальности, поскольку приемник фиксирует более длинный отраженный маршрут. Для имитационного моделирования в настоящей работе принимается следующая стохастическая модель: шум n_i и многолучевая составляющая m_i задаются гауссовскими распределениями с нулевым средним и дисперсиями σ_n^2 и σ_m^2 соответственно, тогда как NLOS-смещение b_i моделируется логнормальным распределением с параметрами μ_b и σ_b , обеспечивающим строго положительное значение смещения.

При известном наборе измерений от N опорных станций задача позиционирования сводится к поиску вектора координат p , минимизирующего взвешенную сумму квадратов невязок:

$$J(p) = \sum_{i=1}^N \omega_i (r_i - \hat{d}_i(p))^2,$$

где $\hat{d}_i(p)$ – модельная дальность, вычисленная по (2), ω_i – весовые коэффициенты, отражающие доверие к каждому дальномерному измерению. В рассматриваемой работе веса используются для учёта различий между LOS, частичным NLOS и полным NLOS, а также для реализации робастной обработки измерений.

В сложной радиосреде карьера особенно важным становится предварительное выделение измерений, полученных в

наиболее неблагоприятных условиях. Для этого могут использоваться пороговые критерии, робастные методы оценки и фильтрация выбросов. В ряде работ показано, что сочетание классификации типа канала и фильтрации ошибки позволяет существенно снизить влияние NLOS и повысить устойчивость координатной оценки. Кроме того, применение внешней инерциальной информации или дополнительной сенсорной поддержки может компенсировать кратковременные потери качества UWB-измерений.

Таким образом, предложенная модель дальнометрии отражает основные источники ошибок UWB-позиционирования в карьере и служит основой для последующего построения алгоритма координатной оценки. В следующем разделе будет рассмотрен порядок вычисления положения подвижного объекта по набору дальномерных измерений с учетом весовой обработки и фильтрации выбросов.

3. Алгоритм оценки координат

По результатам дальномерных измерений положение подвижного объекта определяется решением системы нелинейных уравнений, связывающих неизвестные координаты метки с известными координатами опорных станций. В общем случае, если доступны измерения дальности от NN базовых станций, задача сводится к оценке вектора $\mathbf{p}=[x, y, z]^T$, минимизирующего функционал невязки, сформированный с учетом надежности каждого канала.

Поскольку в условиях карьера часть измерений может быть искажена NLOS-смещением или многолучевостью, прямое решение без предварительной обработки часто приводит к нестабильной координатной оценке. Поэтому на практике целесообразно использовать двухэтапную схему: сначала выполняется отбраковка явно аномальных дальномерных значений, затем решается задача координатной оптимизации по оставшемуся набору измерений.

На первом этапе применяются критерии качества измерений, основанные на величине задержки, дисперсии ошибки, остатке после предварительной аппроксимации или результатах классификации канала. Если измерение признается ненадежным, ему назначается пониженный вес либо оно полностью исключается из решения. Такой подход позволяет уменьшить влияние систематических искажений, особенно в случаях устойчивого NLOS, характерного для карьерных работ.

На втором этапе координаты объекта определяются как решение задачи минимизации взвешенной суммы квадратов невязок:

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p}} \sum_{i=1}^N \omega_i (\hat{d}_i - \sqrt{(x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2})^2$$

Здесь ω_i – коэффициенты доверия к измерениям, определяемые до решения задачи или обновляемые итеративно в процессе оценивания. При равных весах модель сводится к классической трилатерации, однако в сложной радиосреде такой вариант обычно недостаточно устойчив.

Для повышения точности и устойчивости решения целесообразно использовать итерационный метод наименьших

квадратов. На каждой итерации координаты объекта уточняются по линейризованной модели, а веса измерений пересматриваются в зависимости от текущих остатков. В результате система постепенно смещается в сторону более согласованного и физически правдоподобного решения. Такой подход особенно полезен в карьере, где качество измерений может резко меняться при переходе объекта из зоны LOS в зону частичного или полного NLOS.

При наличии дополнительной инерциальной информации возможна интеграция UWB-измерений с данными IMU. В этом случае радиодальнометрия задает абсолютные координатные ограничения, а инерциальный блок обеспечивает сглаживание траектории на коротких интервалах и компенсацию кратковременных провалов качества измерений. Для карьерной техники такая схема является особенно перспективной, поскольку движение объекта обычно носит протяженный и предсказуемый характер, а ошибка координат может быть дополнительно ограничена по кинематическим условиям.

Для оценки координат используется итерационный метод взвешенных наименьших квадратов. На k -й итерации формируются вектор невязок:

$$\mathbf{e}^{(k)} = \mathbf{r} - \hat{\mathbf{d}}(\mathbf{p}^{(k)}),$$

и матрица Якоби $\mathbf{H}^{(k)}$, содержащая производные модельных дальностей по координатам. Итерационный шаг вычисляется как:

$$\begin{aligned} \Delta \mathbf{p}^{(k)} &= (\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{W} \mathbf{e}^{(k)}, \\ \mathbf{p}^{(k+1)} &= \mathbf{p}^{(k)} + \Delta \mathbf{p}^{(k)}, \end{aligned} \quad (4)$$

где $\mathbf{W} = \text{diag}(\omega_i)$ – диагональная матрица весов. Веса обновляются итеративно на основе нормированных остатков, что позволяет уменьшить влияние выбросов в NLOS-каналах.

Для решения задачи координатной оценки использован итерационный метод Гаусса–Ньютона с робастным взвешиванием. В качестве начального приближения использовалось линейное решение трилатерации по первым четырём анкерным станциям. Максимальное число итераций было ограничено значением 20, критерий сходимости – $\Delta \mathbf{p}^{(k)} < 10^{-4}$ м. Если условие сходимости не выполнялось, принималось последнее итерационное значение. Для сценариев с сильными выбросами дополнительно применялось ограничение веса аномальных измерений.

Для подавления грубых выбросов в условиях NLOS использовалась пороговая робастная обработка дальномерных измерений. На каждой итерации координатной оценки вычислялись невязки между измеренными и рассчитанными по текущему приближению дальностями; измерения с абсолютной невязкой более 5 м исключались из пересчёта либо получали пониженный вес. Такой подход позволяет реализовать фильтрацию выбросов без знания истинной координаты объекта в реальном времени.

Для оценки качества полученного решения используются стандартные метрики: средняя ошибка позиционирования, среднеквадратическая ошибка, медианная ошибка и 95-й процентиль. В условиях выраженного NLOS необходимо также анализировать долю выбросов и устойчивость алгоритма к

деградации части опорных каналов. Именно эти показатели позволяют судить о пригодности системы для практического применения в карьере.

Таким образом, предложенный алгоритм оценки координат сочетает взвешенную оптимизацию, фильтрацию недоверенных дальномерных измерений и, при необходимости, инерциальную поддержку. В следующем разделе будет рассмотрена методика экспериментальной или имитационной оценки точности UWB-дальнометрии в типичных сценариях карьерной радиосреды.

4. Экспериментальная методика

Для оценки влияния NLOS-смещения и геометрического фактора на точность UWB-позиционирования в настоящей работе используется имитационная модель, основанная на стохастическом описании ошибки дальности (1). Рассматриваются три канальных сценария: LOS, частичный NLOS и полный NLOS. Для каждого сценария задаются параметры шума σ_n , многолучевой составляющей σ_m и логнормального NLOS-смещения (μ_b, σ_b) , отражающие характерное увеличение ошибки дальнометрии при ухудшении канальных условий.

Параметры гауссового шума σ_n , многолучевого искажения σ_m и логнормального NLOS-смещения μ_b, σ_b выбирались с учётом опубликованных экспериментальных данных по UWB-позиционированию в подземной и промышленной среде, где отмечаются сходные порядки величин ошибок дальномерных измерений и существенные положительные смещения в NLOS-сценариях. При этом используемые в моделировании численные значения носят характер инженерной оценки и отражают типичные уровни шумов и смещений для рассматриваемого диапазона расстояний, а не результат прямой калибровки по конкретному объекту.

Более точная идентификация параметров $\sigma_n, \sigma_m, \mu_b, \sigma_b$ требует натурных измерений в реальной карьерной радиосреде и может быть выполнена, например, по данным, аналогичным представленным в [16].

Дополнительно анализируется влияние геометрии расположения опорных станций, описываемое DOP-подобным геометрическим коэффициентом.

$$DOP = \sqrt{\text{trace}((H^T H)^{-1})}$$

DOP вычислялся для репрезентативной точки рабочей зоны, расположенной в центре рассматриваемого участка, а также проверялся вдоль траектории движения техники.

В сценарии LOS-G станции размещались по периметру рабочей зоны, что обеспечивало значение DOP около 1.2 для центральной точки. В сценариях pNLOS-G и NLOS-G геометрия ухудшалась за счёт смещения одной или нескольких станций к границе зоны наблюдения, вследствие чего DOP возрастал до 1.5 и 1.8 соответственно.

Таким образом, DOP в работе не постулировался, а вычислялся по заданной геометрии. Для благоприятной геометрии анкерные располагались по периметру рабочей области, обеспечивая приблизительно симметричное покрытие зоны пози-

ционирования. Для неблагоприятной геометрии одна из станций смещалась к краю рабочей области, что приводило к росту геометрического фактора и ухудшению обусловленности задачи. Расстояние от объекта до опорных станций варьировалось в диапазоне 20–180 м, что соответствует рабочим условиям карьера среднего масштаба.

Для каждого сочетания канального сценария и геометрии выполняется серия из 5000 прогонов (параметры моделирования в таблице 1), в рамках которой генерируются массивы ошибок дальности и соответствующие координатные ошибки, масштабируемые коэффициентом DOP. В результате формируются оценки средней ошибки, RMSE, медианы, 95-го перцентиля и доли грубых выбросов, превышающих порог 5 м. Отдельно рассчитываются показатели “до” и “после” применения робастной фильтрации, заключающейся в ограничении координатной ошибки сверху на уровне 5 м.

Таблица 1

Параметры имитационного моделирования UWB-позиционирования

Сценарий	Режим	DOP	σ_n , м	σ_m , м	b_i
LOS-G	LOS	1.2	0.05	0.05	0
pNLOS-G	pNLOS	1.5	0.10	0.15	LN (0.4; 0.3)
NLOS-G	NLOS	1.8	0.10	0.20	LN (1.0; 0.4)
LOS-B	LOS	3.0	0.05	0.05	0
pNLOS-B	pNLOS	3.5	0.10	0.15	LN (0.4; 0.3)
NLOS-B	NLOS	4.0	0.10	0.20	LN (1.0; 0.4)

Примечание: G – благоприятная геометрия, B – неблагоприятная; LN – логнормальное распределение.

5. Результаты и обсуждение

Имитационное моделирование позволило количественно оценить влияние канального режима (LOS, частичный и полный NLOS) и геометрии опорных станций на точность UWB-позиционирования карьерной техники. Для каждого сценария было выполнено 5000 прогонов, по результатам которых вычислялись средняя ошибка, среднеквадратическая ошибка (RMSE), медиана, 95-й перцентиль и доля грубых выбросов с ошибкой более 5 м. В качестве показателя влияния геометрии использовался DOP-подобный коэффициент, принимающий значения от 1.2-1.8 для благоприятной геометрии до 3.0-4.0 для неблагоприятной конфигурации анкерных станций.

Для ключевых сценариев дополнительно построены эмпирические функции распределения ошибок и гистограммы остатков. Для RMSE и средней ошибки выполнена бутстрэп-оценка 95% доверительных интервалов по 1000 повторным выборкам. Это позволяет отделить устойчивые эффекты от случайных флуктуаций моделирования.

В таблице 2 приведены результаты имитационного моделирования без применения робастной обработки дальномерных измерений. Как видно из данных, в условиях прямой видимости при благоприятной геометрии (сценарий LOS-G, DOP = 1.2) средняя ошибка позиционирования составляет 0.069 м, RMSE – 0.086 м, медианная ошибка – 0.059 м, а 95-й

процентиль не превышает 0.168 м; грубые выбросы отсутствуют. При переходе к неблагоприятной геометрии (LOS-B, DOP = 3.0) RMSE возрастает до 0.210 м и 95-й процентиль – до 0.408 м, однако координатная ошибка остаётся на уровне, приемлемом для задач мониторинга движения карьерной техники.

Таблица 2

Показатели точности позиционирования
без робастной обработки измерений

Сценарий	DOP	Mean	RMSE	P95	Out, %
LOS-G	1.2	0.069	0.086	0.168	0.00
pNLOS-G	1.5	2.366	2.490	3.751	0.48
NLOS-G	1.8	5.236	5.689	9.549	46.68
LOS-B	3.0	0.168	0.210	0.408	0.00
pNLOS-B	3.5	5.449	5.725	8.682	56.92
NLOS-B	4.0	11.825	12.836	21.387	96.50

В сценариях частичного NLOS влияние канальных искажений становится более заметным. При благоприятной геометрии (pNLOS-G, DOP = 1.5) средняя ошибка составляет 2.366 м, RMSE – 2.490 м, медиана – 2.290 м, а 95-й процентиль – 3.751 м; при этом доля ошибок более 5 м остаётся ниже 1%. При неблагоприятной геометрии (pNLOS-B, DOP = 3.5) RMSE увеличивается до 5.725 м, 95-й процентиль – до 8.682 м, а доля грубых выбросов достигает 56.92%, что указывает на существенное усиление влияния NLOS-смещения и многолучевости при одностороннем размещении анкерных станций.

Наиболее неблагоприятные результаты получены в сценариях полного NLOS. При благоприятной геометрии (NLOS-G, DOP = 1.8) средняя ошибка достигает 5.236 м, RMSE – 5.689 м, медиана – 4.804 м, 95-й процентиль – 9.549 м, а доля ошибок более 5 м – 46.68%. При неблагоприятной геометрии (NLOS-B, DOP = 4.0) координатная ошибка резко возрастает: средняя ошибка составляет 11.825 м, RMSE – 12.836 м, 95-й процентиль – 21.387 м, а доля грубых выбросов превышает 96%, что фактически делает систему непригодной для задач высокоточного позиционирования без дополнительных мер компенсации. Таким образом, сочетание NLOS-смещения и неблагоприятной геометрии является ключевым фактором деградации точности UWB-позиционирования в карьере.

В сценарии полного NLOS робастная обработка дальномерных измерений выполнялась по величине невязки относительно текущей итерационной оценки координат. Измерения с аномально большими отклонениями исключались из расчёта либо получали пониженный вес, что позволило снизить RMSE с 12.84 до 4.97 м.

В таблице 3 представлены соответствующие показатели точности после применения такой обработки. Сопоставление таблиц 2 и 3 показывает, что в LOS-условиях (LOS-G и LOS-B) фильтрация практически не влияет на среднюю ошибку, RMSE и 95-й процентиль, что подтверждает нейтральность выбранной процедуры для штатного режима работы системы.

В условиях частичного NLOS при благоприятной геометрии (pNLOS-G) изменения показателей также минимальны: RMSE снижается лишь с 2.490 до 2.485 м, 95-й процентиль остаётся на уровне 3.751 м, а доля грубых выбросов не изменяется.

Таблица 3

Показатели точности позиционирования после применения пороговой фильтрации дальномерных измерений (отбраковка по невязке >5 м)

Сценарий	DOP	Mean	RMSE	P95	Out raw, %
LOS-G-f	1.2	0.069	0.086	0.168	0.00
pNLOS-G-f	1.5	2.363	2.485	3.751	0.48
NLOS-G-f	1.8	4.277	4.374	5.000	46.68
LOS-B-f	3.0	0.168	0.210	0.408	0.00
pNLOS-B-f	3.5	4.535	4.594	5.000	56.92
NLOS-B-f	4.0	4.970	4.974	5.000	96.50

В то же время при неблагоприятной геометрии (pNLOS-B) эффект робастной обработки становится более заметным: RMSE уменьшается с 5.725 до 4.594 м, а 95-й процентиль и медиана ограничиваются уровнем порядка 5 м, что приводит к снижению чувствительности координатной оценки к аномальным измерениям.

Наиболее существенный выигрыш достигается в сценариях полного NLOS. При благоприятной геометрии (NLOS-G) RMSE снижается с 5.689 до 4.374 м, а 95-й процентиль ограничивается порогом 5 м вместо 9.549 м, что существенно уменьшает риск появления грубых ошибок в траектории. В случае неблагоприятной геометрии (NLOS-B) снижение ещё более выражено: RMSE уменьшается с 12.836 до 4.974 м, а 95-й процентиль ограничивается 5 м вместо 21.387 м, при этом доля исходных выбросов остаётся высокой, но их влияние на координатную оценку существенно подавляется за счёт ограничивающей обработки. Это демонстрирует, что даже простейшая пороговая фильтрация способна радикально уменьшить координатную ошибку в наиболее тяжёлых сценариях, хотя полностью проблему NLOS-смещения и неблагоприятной геометрии она не решает. Дополнительно для ключевых сценариев приведены эмпирические функции распределения координатной ошибки и гистограмма для полного NLOS, что позволяет визуально сопоставить характер отклонений в LOS- и NLOS-условиях и подтвердить результаты, полученные по табличным метрикам (см. рис.1-2).




Рис. 1. Эмпирические функции распределения координатной ошибки UWB-позиционирования для сценариев LOS-G, pNLOS-B и NLOS-B

Из рис. 1 видно, что в сценарии LOS-G 95% ошибок не превышают 0.17 м, тогда как для pNLOS-B соответствующий уровень возрастает до 8.68 м, а для NLOS-B – до 21.4 м. Это подтверждает наличие тяжёлого правого хвоста распределения и резкое ухудшение точности при переходе от прямой видимости к полному NLOS. Гистограмма на рис. 2 показывает, что в сценарии NLOS-B распределение координатной ошибки имеет выраженную асимметрию и концентрируется в диапазоне больших значений, что согласуется с табличными результатами и указывает на необходимость робастной фильтрации измерений.




Рис. 2. Гистограмма распределения координатной ошибки для сценария NLOS-B

В целом полученные результаты подтверждают, что для обеспечения требуемой точности UWB-позиционирования карьерной техники необходимо одновременно решать две задачи: оптимизировать конфигурацию анкерной инфраструктуры с целью снижения DOP-подобного геометрического фактора в рабочих зонах и применять робастные методы обработки дальномерных измерений для подавления грубых выбросов в условиях NLOS. Имитационный характер исследования позволяет варьировать параметры модели и использовать полученные зависимости для предварительной оценки ожидаемой точности при проектировании конкретных систем позиционирования в горных выработках.




Рис. 3. Схема модельного карьера с анкерными станциями, траекторией движения техники и пространственным распределением координатной ошибки

Схематичное представление рабочей зоны на рис. 3 показывает, что рост ошибки связан не только с ухудшением канального режима, но и с локальным снижением геометрической наблюдаемости при заезде техники за уступы. В зонах с преобладанием NLOS ошибка резко возрастает, тогда как в открытых участках при благоприятной геометрии сохраняется дециметровый уровень точности.

Для оценки статистической устойчивости метрик точности дополнительно выполнена бутстрэп-оценка 95-процентных доверительных интервалов для средней ошибки и RMSE с использованием 1000 псевдовыборок для каждого сценария. В случае LOS-G 95-процентный доверительный интервал для RMSE составляет $[0.08; 0.10]$ м, тогда как в неблагоприятном сценарии NLOS-B без фильтрации он достигает $[11.5; 13.9]$ м и уменьшается до $[4.3; 5.6]$ м при использовании предложенной робастной обработки. Это подтверждает статистическую значимость наблюдаемого эффекта уменьшения ошибки и снижает вероятность того, что улучшение обусловлено случайными флуктуациями имитации.

На основе выполненного имитационного моделирования можно сформулировать несколько инженерных рекомендаций по проектированию UWB-системы позиционирования карьерной техники. Во-первых, для обеспечения координатной ошибки на уровне RMSE менее 1 м в рассматриваемой модели требуется не менее четырёх опорных станций, размещённых таким образом, чтобы обеспечивалась симметричная геометрия зоны наблюдения и DOP не превышал 1.8-2.0. Во-вторых, при росте DOP выше 3.0 в условиях частичного и полного NLOS необходимо применять робастную фильтрацию дальномерных измерений, а в наиболее тяжёлых сценариях – дополнять UWB-измерения инерциальной информацией или другими источниками навигационных данных. В-третьих, в зонах полного NLOS использование только UWB-подсистемы без внешней поддержки не обеспечивает требуемой точности для высокоточного мониторинга движения техники. Наконец, при размещении анкерных станций следует избегать конфигураций, при которых одна из станций оказывается смещённой к границе рабочей зоны, поскольку это приводит к ухудшению геометрии и резкому росту ошибки позиционирования.

Полученные в настоящей работе результаты согласуются с опубликованными экспериментальными данными по гибридной UWB/IMU-локализации в условиях ограниченной видимости. В частности, в работе по позиционированию погрузчиков на основе UWB и IMU [16] показано, что интеграция инерциальной информации и улучшенного ESKF существенно повышает устойчивость траектории и снижает долю крупных ошибок по сравнению с чистым UWB-позиционированием: вероятность ошибки в пределах 0.15 м возрастает с 20.1% до 91.9%, а средняя ошибка по осям уменьшается до 0.0157 м и 0.0492 м (см. табл. 4). Это подтверждает, что в сценариях pNLOS/NLOS простая дальномерная схема без дополнительной сенсорной поддержки быстро теряет точность, тогда как даже относительно простая инерциальная коррекция заметно улучшает результаты. В настоящей работе получена аналогичная тенденция: при ухудшении геометрии и росте доли NLOS-искажений ошибка возрастает нелинейно, что указывает на необходимость либо робастной фильтрации

дальномерных измерений, либо интеграции UWB с дополнительными навигационными датчиками. Таким образом, опубликованные результаты подтверждают физическую правдоподобность использованной в работе модели и демонстрируют, что переход от чистого UWB к гибридной схеме является наиболее эффективным способом снижения ошибки в сложной радиосреде.

Таблица 4

Сопоставление результатов

Источник	Среда	Метод	Основной результат	Значение для настоящей работы
Zhu et al., 2025	Подземная парковка, имитация шахтной среды	UWB only	20.1% ошибок в пределах 0.15 м	Показывает ограниченность чистого UWB в NLOS
Zhu et al., 2025	Та же среда	UWB + improved ESKF + IMU	91.9% ошибок в пределах 0.15 м; средняя ошибка по осям 0.0157 м и 0.0492 м	Подтверждает пользу сенсорной интеграции
Настоящая работа	Карьерная среда, имитация LOS/pNLOS /NLOS	UWB simulation	Рост ошибки при ухудшении геометрии и NLOS	Обосновывает влияние DOP и NLOS на точность
Настоящая работа	То же	UWB + робастная обработка	Снижение выбросов и RMSE относительно базовой схемы	Поддерживает вывод о необходимости фильтрации

Заключение

Предложена стохастическая модель ошибок UWB-дальнометрии для карьерной радиосреды, включающая гауссов шум, многолучевую составляющую и логнормальное NLOS-смещение. На основе имитационного моделирования показано, что в LOS-условиях при благоприятной геометрии опорных станций средняя ошибка позиционирования составляет около 0.07 м, RMSE – 0.09 м, а 95-й перцентиль не превышает 0.17 м.

Показано, что при переходе к частичному и полному NLOS координатная ошибка существенно возрастает, причём неблагоприятная геометрия анкерных станций (повышенный DOP) усиливает влияние NLOS-смещения. В полном NLOS при неблагоприятной геометрии RMSE достигает 12.84 м, а доля дальномерных измерений (отбраковка по невязке >5 м) превышает 96%, что ограничивает возможность использования системы без дополнительных мер по обработке измерений.

Исследовано влияние простой робастной обработки дальномерных измерений с ограничением координатной ошибки на уровне 5 м. Порог 5 м для ограничения выбросов выбран исходя из анализа максимальных ошибок в LOS-сценариях и опубликованных данных по UWB-позиционированию, где типичные ошибки при прямой видимости не превышают единиц метров. Таким образом, значения свыше 5 м в рассматриваемом диапазоне расстояний интерпретируются как грубые аномалии, обусловленные NLOS-смещением и сильной многолучевостью, и подлежат подавлению робастной обработкой.

Показано, что в LOS-условиях такая обработка практически не влияет на показатели точности, но в наиболее тяжёлых

сценариях (полный NLOS и неблагоприятная геометрия) позволяет уменьшить RMSE с 12.84 до 4.97 м и ограничить 95-й перцентиль на уровне 5 м, существенно снижая влияние грубых выбросов.

Полученные результаты подтверждают, что при проектировании UWB-систем позиционирования для карьерной техники необходимо уделять первоочередное внимание выбору конфигурации опорных станций, обеспечивающей приемлемые значения геометрического фактора в рабочих зонах техники, а также применению робастных методов обработки дальномерных измерений.

Практическая значимость работы заключается в том, что предложенная модель и результаты имитационного анализа могут использоваться для предварительной оценки ожидаемой точности UWB-позиционирования в конкретных карьерных условиях и для формирования инженерных рекомендаций по размещению UWB-инфраструктуры и настройке алгоритмов фильтрации измерений.

Таким образом, выполненное имитационное исследование показывает, что обеспечение требуемой точности UWB-позиционирования карьерной техники возможно только при совместном учёте геометрии анкерной инфраструктуры, уровня NLOS-искажений и устойчивости алгоритма обработки измерений. Наиболее эффективным является сочетание благоприятного размещения опорных станций, ограничение геометрического фактора и применение робастной фильтрации, что позволяет существенно снизить координатную ошибку даже в сложной радиосреде.

Ограничения работы. Следует отметить, что представленное исследование носит имитационный характер и основано на параметризованной модели ошибок UWB-дальнометрии, параметры которой (σ_n , σ_m , μ_b , σ_b) выбраны на основе литературных данных и инженерных оценок. Отсутствие прямой калибровки модели по натурным измерениям в реальном карьере ограничивает строгость полученных численных рекомендаций и требует последующей верификации. Кроме того, в работе не учитывается динамическая смена состояний LOS/NLOS во времени и возможная зависимость ошибок от кинематики движения, а также не рассматривается интеграция UWB с инерциальными и другими датчиками. Эти вопросы являются предметом дальнейших исследований.

Литература

1. Yu Y., Chen R., Liu Z., Guo G., Ye F., Chen L. Wi-Fi Fine Time Measurement: Data Analysis and Processing for Indoor Localisation // Journal of Navigation. 2020. Vol. 73, pp. 1-23. DOI 10.1017/S0373463320000193.
2. Choi J. Enhanced Wi-Fi RTT Ranging: A Sensor-Aided Learning Approach // IEEE Transactions on Vehicular Technology. 2022. Vol. 71. DOI 10.1109/TVT.2022.3151018.
3. Ziegler M., Kianfar A., Hartmann T., Clausen E. Development and Evaluation of a UWB-Based Indoor Positioning System for Underground Mine Environments // Mining, Metallurgy & Exploration. 2023. Vol. 40. DOI 10.1007/s42461-023-00797-z.
4. Wang L., Zhang S., Qi J., Chen H., Yuan R. Research on IMU-Assisted UWB-Based Positioning Algorithm in Underground Coal Mines // Micromachines. 2023. Vol. 14. Art. 1481. DOI 10.3390/mi14071481.
5. Picazo-Martinez P., Barroso-Fernandez C., Martín Pérez J., Groshev M., de la Oliva A. IEEE 802.11az Indoor Positioning with

mmWave // IEEE Communications Magazine. 2023. DOI 10.1109/MCOM.001.2300454.

6. Liang B., Zhu X., Liu T., Shan G. Non-Line-of-Sight Error Compensation Method for Ultra-Wideband Positioning System // Machines. 2025. Vol. 13. Art. 1018. DOI 10.3390/machines1311018.

7. Wu Y., He M., Li W., Jian I., Yu Y., Chen L., Chen R. Wi-Fi Fine Time Measurement – Principles, Applications, and Future Trends: A Survey // Information Fusion. 2025. Vol. 118. Art. 102992. DOI 10.1016/j.inffus.2025.102992.

8. Kosek-Szott K., Szott S., Ciezobka W., Wojnar M., Rusek K., Segev J. Indoor Positioning with Wi-Fi Location: A Survey of IEEE 802.11mc/az/bk Fine Timing Measurement Research // arXiv. 2025.

9. Gireesh N., Seshagiri T., Avula P., Sujatha C., Panigrahi A.K., Swaraja K., Dilli R. Reliable TOA and TDOA Location Estimation Under Multipath Fading Channel Conditions in Wideband Wireless Networks for Indoor Factory Applications // Wireless Personal Communications. 2025. Vol. 144, pp. 247–274. DOI 10.1007/s11277-025-11849-6.

10. Tong W., Li B., Jing Q. From Error Analysis to Mitigation: A Hybrid Framework for Enhancing Wi-Fi FTM Positioning in Multipath-Prone Indoor Scenarios // IEEE Transactions on Wireless Communications. 2026. Vol. 25, pp. 9859-9874. DOI

10.1109/TWC.2025.3649176.

11. Rajendran G., Sharma K., Chetlapalli V., Parekh J. Performance comparison of 802.11mc and 802.11az Wi-Fi Fine Time Measurement protocols // arXiv. 2025.

12. Huy Cuong H., Fokin G. Joint Maximum Likelihood Time-of-Arrival Estimation in Multipath Channels for Device Positioning in LTE Networks // Proceedings of Telecommunication Universities. 2026. Vol. 12, pp. 81-115. DOI 10.31854/1813-324X-2026-12-1-81-115.

13. Xing Z., Chen J. Unsupervised Radio Map Construction in Mixed LoS/NLoS Indoor Environments // arXiv. 2025. DOI 10.48550/arXiv.2510.08015.

14. Pan Y., Li J., Wu Y., Ji J., Huang C., Wang C.-X. A Channel Charting-Based Semi-Supervised Positioning Algorithm with Co-Training // IEEE Transactions on Communications. 2026. DOI 10.1109/TCOMM.2026.3693171.

15. Antonijević N., Etzlinger B., Singelée D., Preneel B. Secure Wi-Fi Ranging Today: Security and Adoption of IEEE 802.11az/bk // arXiv. 2026. DOI 10.48550/arXiv.2603.18687.

16. Zhu, Zhonghua, Zhao Ying, He Wenxuan, Peng Zhang, Fu Haiying, Wu Yueyue. Positioning of mine loaders based on UWB and IMU // IEEE Access, 2025, pp. 1-1. 10.1109/ACCESS.2025.3605669.

ASSESSMENT OF UWB RANGING ACCURACY FOR POSITIONING QUARRY MACHINERY IN A COMPLEX RADIO ENVIRONMENT

Petr I. Smirnov, Vologda State University, Vologda, Russia, smirnovpi@vogu35.ru

Oleg A. Valyaev, Moscow Automobile and Road Construction State Technical University (MADI), Moscow, Russia, o.valyaev@madi.ru

Natalia I. Baurova, Moscow Automobile and Road Construction State Technical University (MADI), Moscow, Russia, nbaurova@mail.ru

Grigory S. Mazlumyan, Moscow Automobile and Road Construction State Technical University (MADI), Moscow, Russia,

g.mazlumyan@madi.ru

Boris S. Subbotin, Moscow Automobile and Road Construction State Technical University (MADI);

The Kosygin State University of Russia, Moscow, Russia, bsubbotin@mail.ru

Abstract

In open-pit mining environments, high-accuracy positioning of mining vehicles is complicated by the complex geometry of the pit, high benches, metallic structures, and strong multipath propagation, which cause NLOS effects and significant ranging errors. This paper considers the application of ultra-wideband (UWB) technology for vehicle positioning in an open-pit mine and proposes a stochastic ranging error model that accounts for NLOS bias, multipath propagation, and the geometric factor of the anchor layout. Based on simulation, the distribution of position error is analyzed for typical mining radio-environment scenarios (LOS, partial NLOS, and full NLOS) under both favorable and unfavorable UWB anchor geometries. It is shown that under LOS conditions with favorable anchor geometry, the mean positioning error is about 0.07 m, the RMSE is 0.09 m, and the 95th percentile does not exceed 0.17 m, whereas under full NLOS and unfavorable geometry the RMSE increases to 12.84 m. Applying a simple robust preprocessing scheme with a 5 m outlier threshold reduces the RMSE in this scenario to 4.97 m, significantly suppressing gross errors while preserving accuracy in LOS conditions. The practical significance of the study lies in developing recommendations for UWB base-station placement and measurement processing settings that ensure the required monitoring accuracy for mining vehicle movement in a harsh radio environment.

Keywords: ultra-wideband radio (UWB), ranging, positioning, quarry machinery, NLOS, multipath, measurement error, geometric dilution of precision

References

- [1] Y. Yu, R. Chen, Z. Liu, G. Guo, F. Ye, and L. Chen, "Wi Fi fine time measurement: Data analysis and processing for indoor localisation," *J. Navig.*, vol. 73, pp. 1-23, 2020, doi: 10.1017/S0373463320000193.
- [2] J. Choi, "Enhanced Wi Fi RTT ranging: A sensor aided learning approach," *IEEE Trans. Veh. Technol.*, vol. 71, 2022, doi: 10.1109/TVT.2022.3151018.
- [3] M. Ziegler, A. Kianfar, T. Hartmann, and E. Clausen, "Development and evaluation of a UWB based indoor positioning system for underground mine environments," *Min. Metall. Explor.*, vol. 40, 2023, doi: 10.1007/s42461-023-00797-z.
- [4] L. Wang, S. Zhang, J. Qi, H. Chen, and R. Yuan, "Research on IMU assisted UWB based positioning algorithm in underground coal mines," *Micromachines*, vol. 14, art. 1481, 2023, doi: 10.3390/mi14071481.
- [5] P. Picazo Martinez, C. Barroso Fernandez, J. Mart?n P?rez, M. Groshev, and A. de la Oliva, "IEEE 802.11az indoor positioning with mmWave," *IEEE Commun. Mag.*, 2023, doi: 10.1109/MCOM.001.2300454.
- [6] B. Liang, X. Zhu, T. Liu, and G. Shan, "Non line of sight error compensation method for ultra wideband positioning system," *Machines*, vol. 13, art. 1018, 2025, doi: 10.3390/machines1311018.
- [7] Y. Wu, M. He, W. Li, I. Jian, Y. Yu, L. Chen, and R. Chen, "Wi Fi fine time measurement - Principles, applications, and future trends: A survey," *Inf. Fusion*, vol. 118, art. 102992, 2025, doi: 10.1016/j.inffus.2025.102992.
- [8] K. Kosek Szott, S. Szott, W. Ciezobka, M. Wojnar, K. Rusek, and J. Segev, "Indoor positioning with Wi Fi location: A survey of IEEE 802.11mc/az/bk fine timing measurement research," arXiv, 2025.
- [9] N. Gireesh, T. Seshagiri, P. Avula, C. Sujatha, A. K. Panigrahi, K. Swaraja, and R. Dilli, "Reliable TOA and TDOA location estimation under multipath fading channel conditions in wideband wireless networks for indoor factory applications," *Wireless Pers. Commun.*, vol. 144, pp. 247-274, 2025, doi: 10.1007/s11277-025-11849-6.
- [10] W. Tong, B. Li, and Q. Jing, "From error analysis to mitigation: A hybrid framework for enhancing Wi Fi FTM positioning in multipath prone indoor scenarios," *IEEE Trans. Wireless Commun.*, vol. 25, pp. 9859-9874, 2026, doi: 10.1109/TWC.2025.3649176.
- [11] G. Rajendran, K. Sharma, V. Chetlapalli, and J. Parekh, "Performance comparison of 802.11mc and 802.11az Wi Fi fine time measurement protocols," arXiv, 2025.
- [12] H. Cuong and G. Fokin, "Joint maximum likelihood time of arrival estimation in multipath channels for device positioning in LTE networks," *Proc. Telecommun. Univ.*, vol. 12, pp. 81-115, 2026, doi: 10.31854/1813-324X-2026-12-1-81-115.
- [13] Z. Xing and J. Chen, "Unsupervised radio map construction in mixed LoS/NLoS indoor environments," arXiv, 2025, doi: 10.48550/arXiv.2510.08015.
- [14] Y. Pan, J. Li, Y. Wu, J. Ji, C. Huang, and C. X. Wang, "A channel charting based semi supervised positioning algorithm with co training," *IEEE Trans. Commun.*, 2026, doi: 10.1109/TCOMM.2026.3693171.
- [15] N. Antonijevi?, B. Etzlinger, D. Singel?e, and B. Preneel, "Secure Wi Fi ranging today: Security and adoption of IEEE 802.11az/bk," arXiv, 2026, doi: 10.48550/arXiv.2603.18687.
- [16] Z. Zhu, Y. Zhao, W. He, Z. Peng, H. Fu, and Y. Wu, "Positioning of mine loaders based on UWB and IMU," *IEEE Access*, pp. 1-1, 2025, doi: 10.1109/ACCESS.2025.3605669.

Information about authors:

Petr I. Smirnov, Ph.D. (Engineering), Associate Professor of the Department "Automobiles and Automotive Engineering" of the Institute of Mechanical Engineering, Power Engineering and Transport, Vologda State University, Vologda, Russia. ORCID: 0000-0002-9405-7248.

Oleg A. Valyaev, Moscow Automobile and Road Construction State Technical University (MADI), Institute of Automotive and Special Equipment and Engineering, Department of Transport Installations, Senior Lecturer, Moscow, Russia.. ORCID 0009-0000-1025-8388

Natalia I. Baurova, Moscow Automobile and Road Construction State Technical University (MADI), Institute of Automotive and Special Equipment and Engineering, Department of Production and Repair of Automobiles and Road Construction Machinery, Professor, Doctor of Technical Sciences, Moscow, Russia. ORCID 0000-0001-9529-2031

Grigory S. Mazlumyan, Moscow Automobile and Road Engineering State Technical University (MADI), Vice-Rector for Research, Candidate of Technical Sciences, Moscow, Russia. ORCID 0009-0001-9296-0775

Boris S. Subbotin, Ph.D. (Engineering), Moscow Automobile and Road Construction State Technical University (MADI), Senior Researcher, Ph.D. (Engineering), A.N. Kosygin Russian State University, Associate Professor, Moscow, Russia, ORCID 0000-0003-1685-082X

АДАПТИВНЫЙ ПРОТОКОЛ МАРШРУТИЗАЦИИ ДЛЯ МАЛОМОЩНЫХ MESH-СЕТЕЙ ИНТЕРНЕТА ВЕЩЕЙ

DOI: 10.36724/2072-8735-2026-20-5-22-28

Manuscript received 11 February 2026;

Accepted 15 April 2026

Татарникова Татьяна Михайловна,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, г. Санкт-Петербург, Россия,
tm-tatarn@yandex.ru

Янковский Никита Андреевич,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, г. Санкт-Петербург, Россия,
yannik98@yandex.ru

Ключевые слова: mesh-сети, интернет вещей,
протокол RPL, адаптивная маршрутизация, проактивное
управление

Снижение энергопотребления конечными устройствами Интернета вещей, а также увеличение надежности передачи данных являются важнейшими задачами для современных самоорганизующихся сетей. При этом традиционные подходы к маршрутизации в таких сетях, например RPL, имеют недостаточную адаптивность к резким изменениям качества сети и состоянию узлов, что в свою очередь приводит к избыточным повторным передачам пакетов и снижению энергоэффективности устройств. В работе предлагается протокол адаптивной маршрутизации на основе гибридной модели машинного обучения. Протокол предусматривает распределенное размещение обученных моделей случайного леса: на шлюзах сети располагается полновесная система, которая агрегирует данные, полученные с расположенных на промежуточных узлах сети легковесной модели случайного леса. Модель оценивает многомерный набор данных, включающий временные ряды параметров сигнала, энергетический статус и загрузку буферов, и преобразует результат прогноза в динамическую поправку к классической метрике ETX – ожидаемого числа переходов от источника к месту назначения в рамках целевой функции RPL. Результаты имитационного моделирования показывают, что предложенный протокол по сравнению со стандартным протоколом RPL и современными аналогами на основе машинного обучения повышает коэффициент доставки пакетов на 15% в условиях преднамеренных широкополосных помех, увеличивает время жизни сети до первого отказа узла на 20-25% при сохранении приемлемого уровня служебного трафика.

Информация об авторах:

Татарникова Татьяна Михайловна, доктор технических наук, профессор, Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра инфокоммуникационных систем, г. Санкт-Петербург, Россия

Янковский Никита Андреевич, старший преподаватель, Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра инфокоммуникационных систем, г. Санкт-Петербург, Россия

Для цитирования:

Татарникова Т.М., Янковский Н.А. Адаптивный протокол маршрутизации для маломощных mesh-сетей интернета вещей // Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 22-28.

For citation:

T.M. Tatarnikova, N.A. Yankovsky, "Adaptive routing protocol for low-power mesh IoT networks", *T-Comm*, 2026, vol. 20, no.5, pp. 22-28. (in Russian)

Введение

Технологии интернета вещей (Internet of Things, IoT) изменили подходы к мониторингу и управлению в промышленности, городской инфраструктуре, сельском хозяйстве и здравоохранении. Технологической базой интернета вещей являются беспроводные сенсорные сети (БСС), часто реализуемые в виде самоорганизующихся топологий для обеспечения расширенного покрытия, отказоустойчивости и масштабируемости. Узлами таких сетей, как правило, являются автономные устройства с жесткими ограничениями по энергопотреблению, вычислительной мощности и объему памяти [1].

Доминирующим стандартом маршрутизации в самоорганизующихся БСС является протокол RPL (IPv6 Routing Protocol for Low-Power and Lossy Networks), утвержденный организацией по разработке интернет-стандартов – Internet Engineering Task Force (IETF). Согласно протоколу RPL строится направленный ациклический граф DODAG (Destination Oriented Directed Acyclic Graph) относительно корневого узла (рис. 1). Каждый родительский узел является шлюзом или роутером для дочернего узла. Таким образом, если узел не имеет записи в своей таблице маршрутизации для отправки пакета, то он просто пересылает его своему предпочтительному родителю и так далее, пока он не достигнет пункта назначения или общего родительского узла, который пересылает его вниз по дереву к месту назначения. Узлы в сети RPL имеют маршруты для всех узлов вниз по дереву. Это означает, что узлы, расположенные ближе к корневому узлу, имеют большие таблицы маршрутизации.




Рис. 1. Ациклический граф DODAG

Выбор предпочтительного родительского узла – следующей хопа определяется целевой функцией, минимизирующей метрику *ETX* (Expected Transmission Count) – ожидаемое число переходов от источника к месту назначения.

RPL использует три типа управляющих сообщений для создания и поддержки топологии RPL и таблицы маршрутизации:

- информационный объект DODAG (DIO), используемый RPL для формирования, поддержки и обнаружения DODAG;
- запрос информации DODAG (DIS);
- объект объявления пункта назначения DODAG (DAO).

Несмотря на широкое распространение, протокол RPL и большинство его модификаций характеризуются реактивностью: ухудшение канала или отказ узла обнаруживается только после серии неудачных попыток передачи, что приводит к каскадным эффектам, таким как влияние всплеска служебного трафика на перестроение графа, потерю критичных данных, увеличения задержки и, что наиболее важно, нераци-

ональный расход энергии на повторные передачи в деградирувавшем канале. В условиях высокой динамики среды, вызванной подвижностью объектов, интерференцией или изменяющимися условиями распространения радиоволн, эти недостатки становятся критическими.

Возникает необходимость перехода от реактивных к проактивным (прогностическим) механизмам маршрутизации, способным на основе анализа текущего и исторического состояния сети предсказать вероятную деградацию маршрута и инициировать его плановую замену до момента потери связности. Машинное обучение (МО), и, в частности, методы обучения на временных рядах и контекстных данных, представляют собой мощный инструмент для построения таких прогностических моделей. Однако их прямое внедрение в маломощные IoT-устройства наталкивается на непреодолимые барьеры: вычислительная сложность методов МО, объем памяти для хранения модели МО и данных для обучения, энергетическая стоимость инференса.

Основной вклад данной работы заключается в разработке гибридной распределенной архитектуры применения машинного обучения в БСС с топологией mesh, разделяющей вычислительную нагрузку между пограничным шлюзом, где функционирует глобальная сложная модель, и роутерными узлами, выполняющими локальные легковесные модели на основе случайного леса (Random Forest, RF). Интеграция метода RF в протокол RPL обусловлена интерпретируемостью и устойчивостью метода к переобучению и возможностью эффективного сжатия модели RF путем квантизации и прунинга без катастрофической потери точности. В работе предложен полный жизненный цикл применения модели МО в БСС, охватывающий сбор признаков на узлах, локальное прогнозирование, агрегацию данных на шлюзе, глобальное обучение и распространение обновленных легковесных моделей обратно на узлы по схеме, напоминающей федеративное обучение.

Обзор существующих решений

Исследования по интеллектуализации маршрутизации в IoT можно классифицировать по нескольким направлениям:

- место размещения интеллекта: центр и/или периферия;
- используемая методология МО: обучение с учителем, обучение с подкреплением, ансамблевые модели;
- уровень интеграции с сетевым стеком.

К первому направлению относятся исследования, связанные с размещением моделей машинного обучения, что породило варианты архитектурных решений IoT: граничные и туманные (облачные) вычисления.

В работах [2-4] сбор телеметрии осуществляется в центральном контроллере или облаке, где запускаются ресурсоемкие модели, результатом работы которых являются рассчитанные оптимальные маршруты или политики маршрутизации, которые затем загружаются на узлы [5]. Такой подход используется и в полностью централизованных беспроводных системах, например для работы промышленных RFID систем [6] или сотовых сетей IoT [7]. Преимущество такого подхода – это возможность использования сложнейших моделей для глобальной оптимизации. Недостатки являются типичными для многих IoT-сценариев: высокая задержка реакции на локальные события, катастрофический рост служебного

трафика для сбора телеметрии, полная зависимость от работоспособности канала до центра и уязвимость с точки зрения конфиденциальности данных.

Второе направление исследований по интеллектуализации маршрутизации в IoT связано с применением распределенных подходов на основе обучения с подкреплением. Данное направление наиболее активно развивается [8-12]. Каждый узел рассматривается как агент, который взаимодействует со средой – сетью, выбирая действия – следующий хоп, и получает вознаграждение – комбинацию из успешной доставки и затрат энергии. Используются алгоритмы Q-Learning, в которых агент выбирает действия на основе данных из Q-таблицы, где строки обозначают возможные состояния среды, а столбцы – возможные действия агента в этих состояниях или их глубокие версии (Deep Q-Network, DQN), в которых сочетаются принципы Q-обучения с возможностями глубокого обучения. Главные достоинства от применения обучения с подкреплением – полная распределенность и адаптивность. Однако проблемы применительно к IoT заключаются в чрезвычайно медленной сходимости в больших состояниях, необходимости исследования среды, что ведет к периодическому выбору заведомо неоптимальных маршрутов и, как следствие, к потерям пакетов и энергии на этапе обучения. Кроме того, хранение и обновление Q-таблиц или нейросетевых весов потребляет значительную память и вычислительные ресурсы.

Третье направление исследований по интеллектуализации маршрутизации в IoT связано с применением распределенных подходов на основе предобученных легковесных моделей. В работах [13-15] подробно представлены результаты такого исследования: на узлы заранее загружаются простые модели такие как линейные регрессоры, неглубокие деревья решений, наивные байесовские классификаторы, обученные на синтетических или исторических данных. Узлы используют эти модели для оценки качества каналов на основе локальных измерений. Основное преимущество от применения предобученных легковесных моделей – минимальные накладные расходы во время работы. Ключевой недостаток – статичность модели, то есть она не адаптируется к изменениям в сети после развертывания, например, к появлению нового источника помех или изменению паттернов трафика, что со временем ведет к снижению эффективности.

Четвертое направление исследований по интеллектуализации маршрутизации в IoT связано с применением гибридных и иерархических подходов. В недавних исследованиях [16-18], авторы пытаются комбинировать преимущества централизованного и распределенного подходов. Например, на узлах работают легковесные модели, которые периодически отправляют сырые данные или градиенты на шлюз для уточнения глобальной модели. Эти идеи близки к предлагаемому в данной работе подходу, однако часто не учитывают специфику RPL как базового протокола и не предлагают законченных решений для эффективного распространения обновлений моделей в масштабе всей сети.

Предлагаемый в данной статье гибридный подход стремится найти оптимальный баланс между адаптивностью, эффективностью и практической реализуемостью. RF-MeshRPL не требует постоянной связи с центром для принятия решений, но при этом постоянно улучшает свои локальные модели за счет глобального опыта, собранного на шлюзе.

Архитектура и методология протокола RF-MeshRPL

Предполагается развертывание масштабируемой гетерогенной сети, состоящей из сотен узлов, которые можно разделить на три функциональных класса, отражающих их роль и ресурсы:

- Класс 1 (Сенсорные узлы, Leaf Nodes): ресурсо-крайне-ограниченные устройства. Их единственная функция – периодический сбор данных с датчиков и их передача своему непосредственному родителю (узлу Класса 2). Они не участвуют в маршрутизации чужого трафика и не поддерживают модель МО.

- Класс 2 (Роутерные узлы, Router Nodes): узлы с расширенными ресурсами. Они способны ретранслировать трафик, формировать и поддерживать таблицы маршрутизации, а также хранить и исполнять легковесную модель L-RF (Lightweight Random Forest). Эти узлы образуют маршрутизирующий остов сети. Они могут иметь улучшенные источники питания.

- Класс 3 (Пограничный шлюз, Edge Gateway): мощное устройство с постоянным сетевым питанием, значительными вычислительными ресурсами и постоянным подключением к backbone-сети или облаку. Выполняет роль корня DODAG в RPL, агрегирует все данные от сети, а также содержит и периодически переобучает глобальную модель G-RF (Global Random Forest).

Связь между узлами осуществляется по беспроводному каналу стандарта IEEE 802.15.4 (или аналогичного), работающему в диапазоне 2.4 ГГц.

Качество решений модели машинного обучения напрямую зависит от релевантности входных признаков. Каждый роутерный узел (Класс 2) для каждого своего соседа j хранит циклический буфер измерений за временное окно T_w . Каждые T_c секунд (период сбора) узел вычисляет вектор признаков $X_j(t)$.

Выделим четыре категории признаков:

Признаки качества канала:

- $RSSI_{Avg}$ – среднее значение мощности принимаемого сигнала (Received Signal Strength Indicator) за окно T_w ;

- LQI_{Avg} – среднее значение индикатора качества связи (Link Quality Indicator), отражающего соотношение сигнал/шум;

- ETX – текущее расчетное значение ожидаемого числа передач, обновляемое протоколом на основе подсчета успешных/неуспешных передач контрольных пакетов;

- σ_{RSSI} – стандартное отклонение мощности принимаемого сигнала за период времени T_w ;

- PRR – отношение успешно принятых пакетов к отправленным.

Признаки, связанные с энергоэффективностью:

- Класс энергетической стабильности узла (NEC) – дискретный показатель, вычисляемый на основе остаточной емкости батареи согласно следующей шкале:

- 0 (<10%);
- 1 (10-30%);
- 2 (30-60%);
- 3 (60-90%);
- 4 (от сети);

- тренд изменения энергии (убывает/стабилен/растет), вычисляемый как наклон линейной регрессии по последним N измерениям.

Признаки нагрузки узла:

- процент заполненности буфера исходящих пакетов (0-100%). Высокая загрузка указывает на потенциальное узкое место и рост задержек;
- количество дочерних узлов в поддереве. Прокси-метрика потенциальной нагрузки транзитного трафика.

Топологические и временные признаки:

- текущее расстояние от соседа до корневого шлюза;
- время, прошедшее с установления связи с данным соседом. Долгоживущие связи, как правило, более стабильны.

Таким образом, $X_j(t) \in R^d$, где d – общее количество признаков.

Глобальная модель случайного леса (Global Random Forest, G-RF) размещается на пограничном шлюзе. Это классический ансамбль из N_g решающих деревьев, обученный на агрегированном датасете со всей сети, при этом каждое дерево имеет глубину D_g . G-RF решает задачу многоклассовой классификации с четырьмя классами $C = \{0, 1, 2, 3\}$, соответствующими прогнозируемой пригодности канала к соседу j на интервале T_p , ($T_p > T_c$):

- Класс 0: высокая вероятность потери связи или неприемлемого роста ETX в ближайшие T_p ;
- Класс 1: связь сохранится, но с повышенными потерями или задержкой. Не является предпочтительным маршрутом;
- Класс 2: надежный канал с хорошими показателями. Основной кандидат для маршрутизации;
- Класс 3: канал с отличным качеством, высокой энергией узла и низкой нагрузкой. Редкий класс, указывающий на оптимальный путь.

Легковесная модель случайного леса в свою очередь размещается на каждом роутерном узле Класса 2. Это существенно упрощенная и оптимизированная версия G-RF. Легковесная модель получается из глобальной модели путем прунинга и квантования весов, а также с помощью кодирования полученных деревьев.

Механизм адаптивной маршрутизации в RPL

Предлагаемый протокол маршрутизации использует стандартный RPL в качестве транспортной основы, но модифицирует его целевую функцию.

Протокол RPL поддерживает две целевые функции для нахождения оптимального пути:

- объективную функцию OF0, которая определяет минимальное число узлов между отправителем и корневым узлом;
- целевую функцию с гистерезисом MRHOF (Minimum Rank Objective Function with Hysteresis), минимизирующую метрику ETX , при этом используя механизм гистерезиса для снижения частоты смены путей в ответ на небольшие изменения метрики. Гистерезис работает так: при обнаружении нового пути с минимальной стоимостью переход на него происходит только в том случае, если он лучше текущего пути по крайней мере на заданный порог.

Введем композитную метрику $M_{ij}(t)$ для оценки соседа j :

$$M_{ij}(t) = \alpha ETX_{ij}(t) + \beta H_{ij} + \gamma P(C_{ij}(t)), \quad (1)$$

где $ETX_{ij}(t)$ – текущее значение ETX ;

H_{ij} – количество хопов от соседа j до корня (учитывается для минимизации длины пути);

$P(C_{ij}(t))$ – штрафная/премиальная функция, вычисляемая на основе предсказанного моделью класса $C_{ij}(t)$;

α, β, γ – весовые коэффициенты, настраиваемые эмпирически ($\alpha + \beta + \gamma = 1$).

Штрафная функция $P(\cdot)$ определяется следующим образом

$$P(C) = \begin{cases} +\infty, & \text{если } C=0, \\ +3, & \text{если } C=1, \\ 0, & \text{если } C=2, \\ -2, & \text{если } C=3. \end{cases} \quad (2)$$

Процесс выбора родителя на узле i происходит следующим образом:

1. При получении DIO от соседа j узел i извлекает из него актуальные признаки (NEC , число «прыжков» на пути до шлюза, заполненность буфера сообщений).
2. Узел i дополняет эти признаки своими локальными измерениями ($RSSI$, LQI , σ_{RSSI}) для формирования полного вектора X_j .
3. Запускается алгоритм инференса L-RF для X_j , получается $C_{ij}(t)$.
4. Рассчитывается метрика M_{ij} .
5. Из всех соседей выбирается тот, чья метрика M_{ij} минимальна. Он становится новым кандидатом в родители.
6. Собственный ранг узла i пересчитывается как

$$Rank_i = Rank_{Parent} + M_{i,Parent}. \quad (3)$$

Новый ранг анонсируется в исходящих DIO.

Таким образом, прогноз модели напрямую влияет на формирование топологии DODAG, опережая фактические изменения качества каналов.

Ключевым для долгосрочной эффективности системы является механизм обучения. Предлагается цикл, состоящий из следующих этапов:

1. Локальный сбор и разметка данных: каждый роутерный узел не только использует L-RF для предсказаний, но и ведет журнал. Для каждого предсказания $C_{ij}(t)$ он через время T_p записывает фактический исход $C_{ij}(t+T_p)$. Фактический класс определяется по наблюдаемым за период T_p значениям ETX и факту поддержания связи. Формируется локальный датасет $D_i = \left\{ (X_j, C_{True})_k \right\}$.

2. Периодическая отправка логов на шлюз: раз в длительный интервал T_{upload} (например, 6-24 часа) или при накоплении достаточного объема данных, узел отправляет сжатый и агрегированный датасет D_i на шлюз, используя текущую mesh-топологию.

3. Агрегация и глобальное обучение на шлюзе: шлюз собирает датасеты D_i со всех роутерных узлов, формируя глобальный тренировочный набор D_{Global} . На этом наборе проводится дообучение глобальной модели G-RF.

4. Создание новой L-RF и верификация: обученная G-RF подвергается процедурам прунинга и квантизации, в результате чего создается новая версия легковесной модели.

Процедура прунинга подразумевает сжатие модели нейронной сети за счет удаления избыточных или менее важных параметров – нейронов, связей, весов без существенного влияния на точность инференса.

В реализации предлагаемого протокола применяется прунинг по градиенту (Gradient-based pruning) – оценивается важность каждого веса по его вкладу в изменение функции потерь на валидационных данных.

Процедура квантизации подразумевает преобразование весов и активаций из формата с высокой точностью в форматы с меньшей разрядностью, что позволяет уменьшить объём памяти для хранения модели, ускорить вычисления за счет использования целочисленных операций, что особенно важно при инференсе и соответственно, сократить потребление энергии за счет передачи меньшего объема данных через память и выполнение более простых арифметических операций. В реализации предлагаемого протокола применяется пост-тренировочная квантизация (Post-Training Quantization, PTQ) – модель обучается в формате 32-битных чисел с плавающей запятой, после чего веса преобразуются в целочисленные значения.

5. Распространение обновлений модели по сети.

Данный цикл обеспечивает постоянную адаптацию сети к изменяющимся условиям, превращая ее в самообучающуюся систему.

Результаты моделирования

Для проверки эффективности предложенного протокола RF-MeshRPL было произведено моделирование в среде имитационного моделирования NS-3, в котором задействованы все три класса устройств (сенсоры, роутеры, шлюзы). Все узлы используют полный стек 6LoWPAN/RPL. Радиоканал моделируется с учётом затухания, многолучевости и теневого эффекта:

- потери распространения с коэффициентом затухания 3, что характерно для городской застройки;
- замирания сигнала с коэффициентом замирания $m = 1,5$ в зоне прямой видимости, $m = 0,75$ при наличии препятствий;
- фоновая помеха: добавлен шум – 105 dBm, а также периодические широкополосные источники помех, имитирующие работу соседних сетей Wi-Fi/ZigBee.
- подвижные препятствия: перемещающиеся объекты, которые временно затеняют связь моделируются через изменение затухания.

Энергопотребление каждого узла детально моделируется на основе реальных профилей:

Сенсор:

- Сон: 5 мкА
- Прослушивание канала (RX): 18 мА
- Передача (TX, 0 dBm): 25 мА
- Смена состояния: 0.5 мс / 10 мкДж

Роутер:

- Сон: 10 мкА (с сохранением RAM)
- Прослушивание: 20 мА
- Передача: 30 мА (0 dBm)
- Инференс L-RF: 5 мс / 15 мкДж

Моделирование производилось по трем сценариям:

• Сценарий 1 – Базовый: 100 узлов (20 роутеров, 80 сенсоров) равномерно распределены на площади в квадрате 300×300 м. Шлюз в центре. Нет внешних помех, только внутренняя интерференция.

• Сценарий 2 – Динамические помехи: добавлены два источника широкополосных помех, перемещающихся случайным образом и создающих интерференцию на частоте 2.4 ГГц. Периоды помех – по 15 минут через каждые 30 минут.

• Сценарий 3 – Отказоустойчивость: через 2 часа симуляции 20% роутерных узлов выходят из строя (имитация разряда

батареи или аппаратного сбоя). Оценивается время восстановления связности и падение вероятности доставки пакета PDR.

Для оценки преимуществ предложенного протокола RF-MeshRPL выбраны следующие протоколы:

RPL (ETX): стандартный вариант протокола RPL с целевой функцией MRHOF, ориентированной на минимизацию ожидаемого числа передач ETX. Каждый узел самостоятельно выбирает узел для отправки исходя из локально измеренной метрики ETX до каждого соседа. Маршруты строятся в виде направленного ациклического графа DODAG, при этом ранг узла рассчитывается как суммарное ETX по пути до шлюза.

RPL (RSSI): протокол RPL с метрикой на основе усреднённого RSSI. От стандартного варианта RPL (ETX) отличается тем, что выбор родительского узла для передачи осуществляется исходя из максимизации RSSI, а не минимизации числа передач до шлюза.

MA-RPL: подход, объединяющий две метрики ETX и RSSI. Каждый узел рассчитывает скользящее среднее для временных рядов этих двух метрик, а также для их стандартного отклонения. Итоговая метрика получается, как их средневзвешенное значение.

Q-RPL: адаптивный протокол на основе Q-Learning [9]. Реализует распределённое обучение с подкреплением: каждый узел хранит Q-значение для каждого соседа, отражающее ожидаемую полезность выбора этого соседа в качестве родителя. Вознаграждение комбинирует успешность доставки, затраты энергии и задержку. Родительский узел выбирается максимизацией значения Q, при этом оно обновляется при каждой отправке сообщения.

Главная метрика – процент успешно доставленных пакетов от сенсоров до шлюза.

Таблица 1

Средний PDR для разных сценариев, (%)

Протокол	Сценарий 1	Сценарий 2	Сценарий 3
RPL (ETX)	92.3	76.1	70.4
RPL (RSSI)	93.0	79.8	72.1
MA-RPL	94.1	84.2	78.5
Q-RPL	95.7	87.0	81.2
RF-MeshRPL	97.2	93.5	89.8

В базовом сценарии RF-MeshRPL незначительно опережает другие протоколы, но в условиях помех и отказов преимущество становится значительным – до 17 процентных пунктов выше, чем у RPL(ETX) в сценарии 3.

Чтобы оценить энергоэффективность предлагаемого метода маршрутизации для сценария 2 был произведен расчёт средней энергии, затрачиваемой на передачу одного пакета данных, а также время до первого отказа сети из-за разряда батареи. В табл. 2 приведены полученные результаты для всех рассматриваемых протоколов.

Таблица 2

Результаты моделирования

Протокол	Энергия на пакет, мДж	Время до отказа, час.
RPL (ETX)	6.45	148
RPL (RSSI)	5.87	154
MA-RPL	5.49	168
Q-RPL	5.21	176
RF-MeshRPL	4.51	189

Как видно из табл. 2, предлагаемый метод маршрутизации потребляет на 1.94 мДж (30%) меньше энергии на доставленный пакет по сравнению с базовым RPL, что также увеличивает время жизни сети с 148 до 189 часов.

Для сценария 2 также была рассчитана средняя сквозная задержка для пакетов сенсорных устройств: RPL (ETX): 312 мс, RF-MeshRPL: 198 мс. При этом джиттер задержки также уменьшился благодаря более стабильным маршрутам с 82 до 40 мс.

Заключение

Представленный в статье протокол маршрутизации, получившая название RF-MeshRPL, представляет собой значительный шаг вперед в адаптивности и интеллектуальности решений по маршрутизации самоорганизующихся сетей Интернета вещей. Сохраняя основные функции RPL и дополняя их подходом к выбору родительского узла на основе машинного обучения, мы обеспечиваем как сохранение надежности традиционных методов, так и преимущества адаптивного обучения. Предлагаемая иерархическая архитектура, разделенная на глобальную и облегченную модели, делает использование машинного обучения удобным для устройств с ограниченными ресурсами, а федеративный цикл обучения обеспечивает постоянную адаптацию сети к изменяющимся условиям.

Результаты моделирования показывают, что предлагаемый метод позволяет повысить вероятность доставки пакета PDR на 15-18% по сравнению с базовым протоколом RPL для различных сценариев. Также моделирование показало выигрыш в энергоэффективности до 30% по сравнению с протоколом RPL. Так на передачу одного с использованием протокола RF-MeshRPL в среднем тратится всего 4.51 мДж энергии вместо 6.45 при использовании протокола RPL(ETX). Наконец, использование предлагаемого протокола позволило снизить сквозную задержку передачи пакета от сенсорного узла с 312 мс до 198 мс.

Результаты, полученные в данном исследовании, подтверждают перспективность интеграции обучения с подкреплением в протоколы маршрутизации связи, что приводит к повышению производительности mesh-сетей. Дальнейшая работа будет сосредоточена на усовершенствовании RF-MeshRPL с учетом требований качества обслуживания QoS и изучении других моделей обучения с подкреплением для дальнейшего сравнения.

Литература

1. Татарникова Т.М., Богданов П.Ю., Краева Е.В. Предложения по обеспечению безопасности системы умного дома, основанные на оценке потребляемых ресурсов // Проблемы информационной безопасности. Компьютерные системы. 2020. № 4. С. 88-94.
2. Wang Y., Zhang Z., Zhang P., Ma Z., Liu G. A new cloud-based network framework for 5G massive Internet of Things connections //

2017 IEEE 17th International Conference on Communication Technology (ICCT), Chengdu, China, 2017, pp. 412-416.

3. Aldas S., Babakian A. Cloud-Native Service Mesh Readiness for 5G and Beyond // IEEE Access, vol. 11, pp. 132286-132295, 2023

4. Dab B., Fajjari I., Rohon M., Auboin C., Diquélou A. Cloud-native Service Function Chaining for 5G based on Network Service Mesh // ICC 2020 - 2020 IEEE International Conference on Communications (ICC), Dublin, Ireland, 2020, pp. 1-7.

5. Yankovskii N.A., Tatarnikova T.M. Impact of correlated arrival and service flows for radio resource management in centralized wireless networks // T-Comm: Телекоммуникации и транспорт. 2024. Т. 18. № 5. С. 42-48.

6. Цыганкова А.А., Янковский Н.А. Использование методов машинного обучения для предсказания числа меток в RFID системах // Актуальные проблемы и перспективы развития радиотехнических и инфокоммуникационных систем ("Радиоинфоком-2024") : Сборник научных статей по материалам VIII Международной научно-практической конференции, Москва, 18-22 ноября 2024 г. С. 239-243.

7. Янковский Н.А., Татарникова Т.М. Оценка эффективности алгоритмов ассоциации и планирования для передачи чувствительного к задержке трафика по нисходящему каналу беспроводных сетей // Успехи современной радиоэлектроники. 2024. Т. 78, № 8. С. 33-38.

8. Mahajan Smita, Srideviponmalar P., Ramachandran Harikrishnan, Kotecha Ketan. Reinforcement Learning Based Congestion Control Technique for Wireless Mesh Networks // International Journal of Networked and Distributed Computing. 2025.

9. Boushaba Mustapha, Senhaji Hafid Abdelhakim, Belbekkouche Abdelouab, Gendreau Michel. Reinforcement learning based routing in wireless mesh networks // Wireless Networks. 2013.

10. Hu Zhifeng, Han,Chong, Wang Xudong. Deep Reinforcement Learning Based Cross-Layer Design in Terahertz Mesh Backhaul Networks // IEEE/ACM Transactions on Networking. 2023.

11. Dueñas Santos Carlos, Mohamad-Mezher Ahmad, Astudillo Juan, Cárdenas-Barrera Julián, Guerra Eduardo, Meng Julian. Q-RPL: Q-Learning-Based Routing Protocol for Advanced Metering Infrastructure in Smart Grids // Sensors. 2024. 24. 4818. 10.3390/s24154818.

12. Ahmed A.J. et al. Congestion Aware Q-Learning (CAQL) in RPL Protocol – WSN based IoT Networks // 2022 5th International Conference on Engineering Technology and its Applications (IICETA), Al-Najaf, Iraq, 2022, pp. 429-435.

13. Takale D.D. Machine learning techniques for Routing in Wireless sensor network // International Journal of Research and Analytical Reviews. 2023.

14. Rui Kunkun, Pan Hongzhi, Shu Sheng. Secure routing in the Internet of Things (IoT) with intrusion detection capability based on software-defined networking (SDN) and Machine Learning techniques // Scientific Reports. 2023.

15. Murry L. Review on Machine Learning for Intelligent Routing, Key Requirement and Challenges Towards 6G // Computer Networks and Communications. Universal Wiser Publisher Pte. Ltd.

16. Salama A., Stergioulis A., Zaidi S.A.R., McLernon D. Decentralized Federated Learning on the Edge Over Wireless Mesh Networks // IEEE Access, vol. 11, pp. 124709-124724, 2023.

17. Wang Y., Wen Z., Li Y., Cao B. Learn to Collaborate in MEC: An Adaptive Decentralized Federated Learning Framework // IEEE Transactions on Mobile Computing, vol. 23, no. 12, pp. 14071-14084, Dec. 2024.

18. Sloop J. et al. Federated Learning for MCS Selection in 5G Side-link MANETs // MILCOM 2025 – 2025 IEEE Military Communications Conference (MILCOM), Los Angeles, CA, USA, 2025, pp. 612-617.

ADAPTIVE ROUTING PROTOCOL FOR LOW-POWER MESH IOT NETWORKS

Tatyana M. Tatarnikova, SUAI, St. Petersburg, Russia, tm-tatarn@yandex.ru

Nikita A. Yankovsky, SUAI, St. Petersburg, Russia, yannik98@yandex.ru

Abstract

Reducing power consumption by IoT endpoints and increasing data reliability are critical for today's self-organizing networks. At the same time, traditional approaches to routing in such networks, for example RPL, have insufficient adaptability to sudden changes in network quality and node status, which in turn leads to excessive packet retransmissions and a decrease in the energy efficiency of devices. The paper proposes an adaptive routing protocol based on a hybrid machine learning model. The protocol provides for the distributed placement of trained random forest models: a full-fledged system is located on the network gateways, which aggregates data received from the lightweight random forest model located on intermediate network nodes. The model estimates a multivariate data set including time series of signal parameters, energy status and buffer loading, and converts the forecast result into a dynamic correction to the classical ETX metric – the expected number of transitions from source to destination within the RPL objective function. The simulation results show that the proposed protocol, in comparison with the standard RPL protocol and modern machine learning-based counterparts, increases the packet delivery rate by 15% in conditions of deliberate broadband interference, increases the network lifetime to the first node failure by 20-25% while maintaining an acceptable level of service traffic.

Keywords: mesh networks, IoT, RPL, adaptive routing, proactive management

References

- [1] T.M. Tatarnikova, P.Yu. Bogdanov, E.V. Kraeva, "Smart Home Security Suggestions Based on Resource Assessment," *Information Security Issues. Computer systems*. 2020. No. 4, pp. 88-94.
- [2] Y. Wang, Z. Zhang, P. Zhang, Z. Ma and G. Liu, "A new cloud-based network framework for 5G massive Internet of Things connections," *2017 IEEE 17th International Conference on Communication Technology (ICCT)*, Chengdu, China, 2017, pp. 412-416
- [3] S. Aldas and A. Babakian, "Cloud-Native Service Mesh Readiness for 5G and Beyond," in *IEEE Access*, vol. 11, pp. 132286-132295, 2023
- [4] B. Dab, I. Fajjari, M. Rohon, C. Auboin and A. Diqui?lou, "Cloud-native Service Function Chaining for 5G based on Network Service Mesh," *ICC 2020 – 2020 IEEE International Conference on Communications (ICC)*, Dublin, Ireland, 2020, pp. 1-7.
- [5] N.A., Yankovskii, T.M. Tatarnikova, "Impact of correlated arrival and service flows for radio resource management in centralized wireless networks," *T-Comm*. 2024. Vol. 18. No. 5, pp. 42-48.
- [6] A. Tsygankova, N.A. Yankovsky, "Using machine learning methods to predict the number of tags in RFID systems," *Actual problems and prospects for the development of radio engineering and infocommunication systems ("Radio Infocom-2024")*: Collection of scientific articles based on materials from the VIII International Scientific and Practical Conference, Moscow, November 18-22, 2024, pp. 239-243.
- [7] N.A. Yankovsky, T.M. Tatarnikova, "Evaluation of the efficiency of association and scheduling algorithms for the transmission of delay-sensitive traffic over the downlink of wireless networks," *Successes of modern radio electronics*. 2024. Vol. 78, no. 8, pp. 33-38.
- [8] Mahajan Smita, Srideviponmalar P., Ramachandran Hari Krishnan, Kotecha Ketan, "Reinforcement Learning Based Congestion Control Technique for Wireless Mesh Networks," *International Journal of Networked and Distributed Computing*. 2025.
- [9] Boushaba Mustapha, Senhaji Hafid Abdelhakim, Belbekkouche Abdeltouab, Gendreau Michel, "Reinforcement learning based routing in wireless mesh networks," *Wireless Networks*. 2013.
- [10] Hu Zhifeng, Han Chong, Wang Xudong, "Deep Reinforcement Learning Based Cross-Layer Design in Terahertz Mesh Backhaul Networks," *IEEE/ACM Transactions on Networking*. 2023.
- [11] Duenas Santos Carlos, Mohamad-Mezher Ahmad, Astudillo Juan, Cardenas-Barrera Julian, Guerra Eduardo, Meng Julian, "Q-RPL: Q-Learning-Based Routing Protocol for Advanced Metering Infrastructure in Smart Grids. Sensors," 2024. 24. 4818. 10.3390/s24154818.
- [12] A. J. Ahmed et al., "Congestion Aware Q-Learning (CAQL) in RPL Protocol – WSN based IoT Networks," *2022 5th International Conference on Engineering Technology and its Applications (IICETA)*, Al-Najaf, Iraq, 2022, pp. 429-435.
- [13] D.D. Takale, "Machine learning techniques for Routing in Wireless sensor network," *International Journal of Research and Analytical Reviews*. 2023.
- [14] Rui Kunkun, Pan Hongzhi, Shu Sheng, "Secure routing in the Internet of Things (IoT) with intrusion detection capability based on software-defined networking (SDN) and Machine Learning techniques," *Scientific Reports*. 2023.
- [15] L. Murry, "Review on Machine Learning for Intelligent Routing, Key Requirement and Challenges Towards 6G," *Computer Networks and Communications*. Universal Wiser Publisher Pte. Ltd.
- [16] A. Salama, A. Stergioulis, S. A. R. Zaidi and D. McLernon, "Decentralized Federated Learning on the Edge Over Wireless Mesh Networks," in *IEEE Access*, vol. 11, pp. 124709-124724, 2023
- [17] Y. Wang, Z. Wen, Y. Li and B. Cao, "Learn to Collaborate in MEC: An Adaptive Decentralized Federated Learning Framework," in *IEEE Transactions on Mobile Computing*, vol. 23, no. 12, pp. 14071-14084, Dec. 2024
- [18] J. Sloop et al., "Federated Learning for MCS Selection in 5G Sidelink MANETs," *MILCOM 2025 – 2025 IEEE Military Communications Conference (MILCOM)*, Los Angeles, CA, USA, 2025, pp. 612-617.

ОБНАРУЖЕНИЕ РЕДКОЙ АНОМАЛЬНОЙ АКТИВНОСТИ ПОЛЬЗОВАТЕЛЕЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

DOI: 10.36724/2072-8735-2026-20-5-29-38

Manuscript received 28 February 2026;

Accepted 30 April 2026

Шелухин Олег Иванович,
 Московский технический университет связи
 и информатики, Москва, Россия,
sheluhin@mail.ru

Осин Андрей Владимирович,
 Московский технический университет связи
 и информатики, Москва, Россия,
a.v.osin@mtuci.ru

Ключевые слова: информационные системы, инсайдер,
 аномальная активность, поведенческий профиль,
 кластерное соседство

Цель исследования: повышение эффективности противодействия инсайдерам в информационных системах за счет построения адекватной модели аномального поведенческого профиля пользователей CRM-систем методами машинного обучения. На основе предложенного подхода идентифицируются потенциальные инсайдеры. Методы исследования: аналитический обзор релевантных научных публикаций в области обнаружения аномальной активности пользователей при работе с информационными системами; поведенческий анализ в сочетании с алгоритмами машинного и глубокого обучения, открывающий новые возможности для раннего выявления инсайдерских угроз. Полученные результаты: Разработан обобщенный алгоритм обнаружения редкого аномального поведения пользователя информационных систем. Показано, как методами машинного обучения может быть сформирована эталонная база кластерных образцов аномальных объектов. Для обнаружения аномальной активности пользователей предложено сравнивать кластерное представление нового объекта с эталонными образцами по метрике сходства, что позволяет оценить, насколько поведение пользователя похоже на ранее зафиксированные аномалии. Научная новизна работы определяется авторским подходом к противодействию редкой аномальной активности пользователей информационных систем на основе сравнения типовых нормальных поведенческих профилей и поведенческих профилей инсайдеров с использованием методов интеллектуального анализа данных.

Информация об авторах:

Шелухин Олег Иванович, Московский технический университет связи и информатики, д.т.н., профессор, заведующий кафедрой "Информационная безопасность", Москва, Россия. ORCID: <https://orcid.org/0000-0001-7564-6744>

Осин Андрей Владимирович, Московский технический университет связи и информатики, к.т.н., доцент, кафедра "Информационная безопасность", Москва, Россия. ORCID: <https://orcid.org/0000-0002-6384-9365>

Для цитирования:

Шелухин О.И., Осин А.В. Обнаружение редкой аномальной активности пользователей информационной системы методами машинного обучения // T-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 29-38.

For citation:

O. I. Sheluhin, A.V. Osin, "Detecting Rare User Behavior Anomalies in Information Systems with Machine Learning," T-Comm, 2026, vol. 20, no.5, pp. 29-38. (in Russian)

Введение

Вопрос выявления аномальной активности пользователей в информационных системах приобретает всё большую актуальность в условиях роста внутренних и внешних угроз информационной безопасности [1, 2, 17]. Под аномальной активностью понимаются действия, отклоняющиеся от типичных временных, географических и функциональных характеристик поведения конкретного пользователя [17]. Выявление таких отклонений опирается на построение поведенческого профиля, позволяющего различать нормальную и подозрительную активность [17, 19].

Одной из наиболее опасных форм аномального поведения является инсайдерская угроза, связанная с действиями сотрудников, подрядчиков или иных лиц, имеющих легитимный доступ к ресурсам организации, а также с атаками, имитирующими поведение доверенного пользователя [3-5].

Сложность обнаружения инсайдеров обусловлена тем, что их активность нередко осуществляется в рамках формально допустимых полномочий и с учётом знания внутренних процессов. В работе [5] выделяются невольные нарушители, злонамеренные субъекты, недовольные сотрудники и внешние специалисты, получившие доступ к внутренней инфраструктуре.

К числу признаков аномального поведения относятся входы в нерабочее время, множественные неудачные попытки аутентификации, обращения к нетипичным ресурсам, всплески сетевой активности, использование нестандартных устройств, IP-адресов или географических точек доступа, подозрительные операции с файлами, а также попытки обхода средств защиты [15-17]. Подобные отклонения особенно значимы в системах, содержащих критически важные и чувствительные данные.

Особое место среди таких систем занимают CRM-платформы, предназначенные для хранения клиентских данных, автоматизации взаимодействия с клиентами и поддержки бизнес-процессов. Высокая концентрация коммерчески значимой информации делает CRM-системы привлекательной целью как для внешних злоумышленников, так и для инсайдеров.

Внешние атаки обычно требуют значительных ресурсов, эксплуатации уязвимостей, компрометации учетных данных или применения фишинга и вредоносного ПО, а также сопровождаются заметным риском обнаружения [9].

В отличие от внешнего нарушителя, инсайдер обладает не только санкционированным доступом к CRM-системе, но и пониманием её логики, бизнес-контекста и организационных слабых мест [10, 11]. Это делает его действия менее заметными и существенно осложняет своевременное выявление угроз. В связи с этим традиционные средства периметральной защиты оказываются недостаточными, а приоритет смещается в сторону мониторинга поведения пользователей и обнаружения нетипичных, но формально допустимых действий [6-8, 17, 19]. Следовательно, разработка методов выявления аномальной активности пользователей в CRM-системах представляет собой актуальную задачу обеспечения информационной безопасности.

Целью статьи является построение адекватной модели аномального поведенческого профиля пользователей CRM-систем, на основе которой методами машинного обучения идентифицируются потенциальные инсайдеры [18-20].

1 Аномальное поведение пользователя

1.1 Постановка задачи

Функционал CRM-системы очень широк. Обычно, в рамках ролей, выданных пользователем, известно, каким функционалом пользуется представитель данной роли. Если внезапно этот функционал резко меняется, а пользователь выполняет неожиданные действия, которые ранее он не делал, то, подобные действия также можно идентифицировать как аномальное поведение и делать из этого соответствующие выводы [17].

При работе с пользователем системы нужно обращать внимание на предупреждение системы безопасности, которая в том или ином виде всегда встроена в информационную систему. Например, когда несколько раз фиксируются попытки ввода неправильного пароля, или когда пользователь включил VPN для того, чтобы подключиться к этой информационной системе [6]. В случае использования такого-то вредоносного кода пользователь может попытаться повысить свои привилегии до администратора и получить те права, на которые он изначально не был подписан.

Рассмотренные проявления позволяют отнести поведение пользователя к категории потенциально опасного, поскольку именно такие отклонения нередко предшествуют утечкам информации и реализации инсайдерских сценариев [1, 11]. При анализе внутренних угроз существенное значение имеют не только отдельные подозрительные действия в информационных системах, но и общая динамика изменений в поведении сотрудника [17].

На практике о повышенном риске инсайдерской активности могут свидетельствовать две группы признаков. Первая связана с цифровым следом пользователя и включает появление нетипичных действий в корпоративных информационных системах [17]. Вторая относится к изменению поведенческого состояния сотрудника, которое может проявляться в снижении эффективности работы, ослаблении вовлечённости в рабочие процессы или изменении привычного характера взаимодействия с системой.

Основанием для вывода об аномальном поведении может служить фиксация активности, нехарактерной для конкретного пользователя в обычных условиях [17]. К числу таких проявлений относятся резкие отклонения от типового сценария работы, необычно высокий уровень потребления ресурсов, а также изменение шаблона взаимодействия с системой. Последнее может выражаться в переходе к новым разделам, вкладкам или функциям, которые ранее не были свойственны данному пользователю. В совокупности такие признаки позволяют рассматривать сотрудника как потенциальный объект дополнительного мониторинга и поведенческого анализа [17, 19].

Отдельной категорией аномального поведения являются резкие скачки поведения пользователя, когда фиксируются новые паттерны в его поведении. Например, когда объем информации, связанный с пользователем, составлял ранее несколько мегабайт в час, а в текущем времени зафиксирован скачок, например, до 100 мегабайт в час [15, 16]. Скачки такого рода также являются признаками или типом аномального поведения. Анализ перечисленных аномальных событий позволяет перейти к оценке того, кто является их источником (актором).

Это могут быть либо инсайдеры-сотрудники, которые допущены во внутренний периметр безопасности информационной системы, либо хакеры, которые пытаются вторгнуться извне, используя методики и социальной инженерии, либо атаки, или иные способы (вирусы, черви и так далее). Это могут быть внешние манипуляторы - люди, которые пытаются своими связями, знакомствами проникнуть внутрь периметра безопасности информационной системы и вынудить людей находящихся внутри на выполнение противоправных действий.

В рамках рассмотрения систем, занимающихся аномальным поведением пользователей, известны несколько типов подобных систем [1, 14]. В частности, это UBA (User Behavior Analytics), технология в информационной безопасности, которая анализирует поведение пользователей и выявляет необычные или подозрительные действия (аномалии), которые могут указывать на угрозы [17]. Продвинутой версией UBA является UEBA (User and Entity Behavior Analytics). Данный класс систем кроме поведения пользователей рассматривает и поведение отдельных узлов системы [17].

Ключевой задачей систем выявления аномального поведения является формирование поведенческой модели пользователя, позволяющей оценивать степень отклонения текущей активности от ожидаемой [17, 19]. При обнаружении существенных отклонений важно не только зафиксировать аномалию, но и сопоставить её с ранее выявленными сценариями аномального поведения для более точной идентификации потенциального нарушителя и классификации угрозы [19, 20]. Таким образом, поведенческий профиль должен служить основой как для описания нормальной активности, так и для выделения характерных признаков поведения инсайдера.

2 Обобщённый алгоритм обнаружения аномального поведения пользователя

Обобщенная структура алгоритма обнаружения аномального поведения пользователя [13] может быть представлена в виде последовательности из пяти этапов, представленных на рис. 1.




Рис. 1. Структура алгоритма обнаружения аномального поведения пользователя

Этап 1. Сбор данных. Журнал событий

На первом этапе система отслеживает события, происходящие в результате работы пользователя информационной системы. Среди этих событий можно выделить следующие:

- сколько времени пользователь проводит на определенной вкладке информационной системы;
- что пользователь копирует в буфер обмена;
- есть ли в том, что скопировал пользователь в буфер обмена, персональные данные;
- как часто изменяется клавиатурный почерк пользователя («мышинный почерк»).

Эти типы поведения могут быть оределены на основе следующих показателей:

- частота использования клавиатуры;
- как быстро он двигает курсор мыши при работе в различных разделах информационной системе;
- какое ускорение этого курсора, как быстро и нервно он осуществляет скроллинг (от англ. scrolling—«прокрутка») действие, которым пользователь перемещает содержимое на экране своего гаджета, чтобы увидеть скрытую за границами дисплея часть.

В результате анализа подобных событий формируется вектор, содержащий все элементы, характеризующие различные аспекты поведения пользователя при взаимодействии с информационной системой. Несложно предположить, если пользователь выполняет свои рутинные функции, он достаточно спокоен, выполняет их изо дня в день и этот шаблон его поведения повторяется. Однако, как только у пользователя появляется намерение выполнить какое-то негативное действие (например украсть что-то), то, скорее всего, в каком-то одном или в нескольких из этих показателей это проявится.

Это, например, может проявиться в виде какого-то нервного движения мыши, или пользователь перестанет заходить на какую-то вкладку, а будет больше внимания уделять тем разделам системы, где хранятся действительно ценные данные или среди них можно выделить ряд категорий данных, таких как: аккумуляторный почерк; «мышинный почерк»; анализ буфера обмена; пользовательская активность; нахождение пользователя в разделах информационной системы (открытие пользователем определенных вкладок в определенные интервалы времени).

Фиксация действий пользователя в сервисной системе требует использования унифицированного формата представления данных, пригодного для последующей автоматизированной обработки. Одним из наиболее распространённых решений является формат JSON (JavaScript Object Notation), предназначенный для хранения и передачи структурированной информации. Несмотря на связь с синтаксисом JavaScript, данный формат является платформенно независимым и поддерживается широким кругом языков программирования. Представленные в нём записи содержат набор характеристик, описывающих действия пользователя и позволяющих формировать признаки для анализа его поведения. Среди них есть в том числе и параметры курсора мыши при работе.

Из множества показателей можно увидеть, какова история изменения почерка, каково содержимое курсора обмена, какова активность пользователя на определенной вкладке, какой процент времени он там провел и т.д. Это могут быть в том числе данные о том на какие кнопки пользователь нажимал, какие выгружал файлы и т.д. В результате, в реальном времени создается набор JSON-логов, который фиксируется и анализируется с целью формирования информации необходимой для построения профиля функционирования каждого пользователя.

Рассмотрим набор данных, получаемых из CRM-системы через сниффер, который представляет собой записи пяти логов данных пользователя в формате json-файла. Для удобства представления данных json-файлы логов могут быть открыты в браузере. Поле «path» является вкладкой (страницей), на которой находится пользователь. В конце каждого файла присутствует поле «user_id», означающее идентификатор пользователя в CRM-системе.

Записи в каждом из пяти логов содержат поля:

- $crm_user_club_id$ – идентификатор клуба пользователя в системе;
- crm_user_fio – фамилия, имя и отчество пользователя в системе;
- crm_user_role – роль пользователя в системе;
- $data$ – массив данных для каждой записи.

Признаки (атрибуты) действий пользователя с мышью:

$\{a_{дм.i}, i = \overline{1, I}, I = 11\}$

- $metric_id$ – идентификатор записи действия пользователя с мышью;
- $path$ – URL-адрес или идентификатор вкладки;
- $created_at$ – время записи действия пользователя с мышью;
- $start_at$ – время начала действия пользователя с мышью;
- end_at – время окончания действия пользователя с мышью;
- $left_clicks$ – количество левых кликов пользователя на вкладке;
- $right_clicks$ – количество правых кликов пользователя на вкладке;
- $scroll_up$ – количество прокруток пользователем вверх;
- $scroll_down$ – количество прокруток пользователем вниз; $average_acceleration$ – среднее ускорение движения курсора (пиксель/миллисекунду);
- $average_speed$ – средняя скорость движения курсора (пиксель/секунду).

Признаки (атрибуты) действий пользователя с клавиатурой: $\{a_{дк.j}, j = \overline{1, J}, J = 7\}$

- $metric_id$ – идентификатор записи действия пользователя с клавиатурой;
- $path$ – URL-адрес или идентификатор вкладки;
- $created_at$ – время записи действия пользователя с клавиатурой;
- $start_at$ – время начала действий пользователя с клавиатурой в секундах;
- end_at – время окончания действий пользователя с клавиатурой в секундах;
- $average_speed$ – средняя скорость нажатия на клавиши (пиксель/миллисекунду);
- $average_press_time$ – среднее время нажатия на клавиши в миллисекундах.

Признаки (атрибуты) пользовательской активности: $\{a_{да.k}, k = \overline{1, K}, K = 7\}$

- $metric_id$ – идентификатор записи пользовательской активности;
- $path$ – URL-адрес или идентификатор вкладки;
- $created_at$ – время записи;
- пользовательской активности в секундах;
- $start_at$ – время начала активности пользователя в секундах;
- end_at – время окончания активности пользователя в секундах;

- $active$ – время активности пользователя на вкладке в миллисекундах;
- $inactive$ – время неактивности пользователя на вкладке в миллисекундах.

Признаки (атрибуты) действий пользователя с буфером обмена: $\{a_{дв.l}, l = \overline{1, L}, L = 5\}$

- $metric_id$ – идентификатор записи действия пользователя с буфером обмена;
- $path$ – URL-адрес или идентификатор вкладки;
- $created_at$ – время записи действия пользователя с буфером обмена в секундах;
- $copied_at$ – время копирования данных пользователем в буфер обмена в секундах;
- $data$ (вложенный словарь) – это может быть, например, сумма продаж за определенный период.

Признаки (атрибуты) событий пользователя на вкладке: $\{a_{дв.m}, m = \overline{1, M}, M = 5\}$

- $metric_id$ – идентификатор записи события пользователя на вкладке;
- $path$ – URL-адрес или идентификатор вкладки;
- $created_at$ – время записи события пользователя на вкладке в секундах;
- $event_at$ – метка времени события в секундах;
- $type$ – тип события пользователя на вкладке.

При анализе можно такие структуры легко выявить случаи появления в буфере обмена персональных данных пользователя. Общий вектор атрибутов имеет вид

$$A = \{a_{дм.i}, a_{дк.j}, a_{да.k}, a_{дв.l}, a_{дв.m}, i = \overline{1, I}, j = \overline{1, J}, k = \overline{1, K}, l = \overline{1, L}, m = \overline{1, M}\}.$$

Этап 2. Агрегирование по интервалам

На втором этапе решается задача преобразования полученного достаточно разнородного набора данных к некоторым стандартизованным агрегированным интервалам. Агрегация данных является важным этапом в работе системы и выполняется следующим образом.

Для каждой вкладки, перечисленные логи агрегируются в заданном временном интервале. Для определенности будем агрегировать полученные данные (логи событий в системе) по 5-минутным интервалам, как это показано на рис. 2.

Пример представления агрегированных данных метрики агрегированной активности пользователя на вкладке CRM-системы имеет вид.

- $active_percentage$ – процент активности = (сумма времени активности / (сумма времени активности + сумма времени не активности)) – пользователя;
- $average_active$ – средняя активность пользователя в минутах = (процент активности / количество открытий пути пользователем)
- $opening_amount$ – количество открытий пользователем вкладки;
- $aggregation_id$ – номер записи агрегации;
- day_time – временной интервал суток (ночь, день, вечер) на основе времени начала активности (час дня);
- $path$ – URL – адрес или идентификатор вкладки;

- `created_at` – время записи активности пользователя в секундах;
- `start_at` – время начала активности пользователя в секундах;
- `end_at` – время окончания активности пользователя в секундах.




Рис. 2. Схема агрегирования атрибутов по пятиминутным интервалам

Аналогично находятся атрибуты для агрегированных действий с мышью пользователя на вкладке; агрегированных событий пользователя на вкладке; агрегированных данных действий пользователя с клавиатурой на вкладке; агрегированных данных буфера обмена пользователя на вкладке.

При нахождении нескольких типов событий в одном пятиминутном интервале для каждого типа атрибута создается отдельный столбец. Затем, в рамках каждого агрегированного 5-минутного интервала формируется вектор, $A = \{a_1, a_2, \dots, a_n, n = \overline{1, N}, N = I + J + K + L + M\}$ содержащий элементы, соответствующие введенным показателям. В результате агрегирования формируется структурированная база данных, которая хранится в электронном виде на компьютере или специальном сервере.

Этап. 3 Обнаружение аномального поведения

На третьем этапе с помощью искусственных нейронных сетей (ИНС) осуществляется обнаружение аномального поведения пользователей. Вариант структуры ИНС в виде автокодировщика (АК) иллюстрируется на рисунке 3.




Рис. 3. Структура обработки данных каждой вкладки с помощью АК

Как известно [14] автокодировщик представляет собой композицию двух функций: $AE(x) = Decoder(Encoder(x)) = \hat{x}$, где $x \in \mathbb{R}^N$ – выходной нормализованный вектор; $\hat{x} \in \mathbb{R}^N$ – реконструированный выход. Encoder (кодер) сжимает данные до скрытого пространства, а Decoder восстанавливает данные из сжатого представления.

АК обучается на основании минимизации ошибки реконструкции и для некоторых пятиминутных интервалов считает их аномальными соответствующими аномальным поведением пользователей. Количество АК соответствует числу вкладок действий пользователя CRM-системы. Для выявления аномального поведения пользователя для каждого пятиминутного интервала для каждой вкладки вычисляется ошибка реконструкции. Архитектура кодера описывается функцией отображения $f_{enc}: \mathbb{R}^N \rightarrow \mathbb{R}^d$, где $d < N$ и может быть описана как последовательность линейных преобразований и нелинейностей вида

$$z = f_{enc}(x) = \sigma^{(L)}(W^{(L)} \dots \sigma^{(1)}(W^{(1)}x + b^{(1)}) + \dots + b^{(L)}) \quad (1)$$

где $W^{(l)}, b^{(l)}$ – веса и смещения на уровне l ; $\sigma^{(l)}$ – функция активации (обычно ReLU, tanh, sigmoid); $z \in \mathbb{R}^d$ – сжатое (бутылочное) представление.

Архитектура декодера описывается функцией восстановления $f_{dec}: \mathbb{R}^d \rightarrow \mathbb{R}^N$ и строится аналогично (1) в виде последовательности преобразований:

$$\hat{x} = f_{dec}(z) = \phi^{(M)}(V^{(M)} \dots \phi^{(1)}(V^{(1)}z + c^{(1)}) + \dots + c^{(M)}) \quad (2)$$

где $V^{(m)}, c^{(m)}$ – веса и смещения на уровне слоя m соответственно; $\phi^{(m)}$ – функция активации (обычно симметрична $\sigma^{(l)}$); $\hat{x} \in \mathbb{R}^N$ – восстановленный вектор. Данные, сжатые в «узком слое», восстанавливаются в выходном слое.

На заключительном этапе вычисляется функция потерь, которая оценивается как среднеквадратичная ошибка (MSE – Mean Squared Error.) реконструкции для тренировочных данных для обновления весов модели. Для тестовых данных ошибка реконструкции вычисляется путем усреднения по всему подмножеству данных $\mathcal{L}(x, \hat{x}) = \frac{1}{N} \sum_{j=1}^N (x_j - \hat{x}_j)^2$.

Без анализа реальных событий сложно судить о том на сколько эти аномалии относятся или не относятся к инсайдерским действиям. Для этого нужна эталонная матрица, задающая срез поведения пользователя, когда АК, обученный на заданном интервале, признал эти участки нормальными. В эталонной матрице содержатся примеры нормального и аномального поведения, которые формирует АК.

Этап. 4. Формирование эталонной матрицы

Предлагается предварительно разделить поведенческие временные интервалы на «типовые», «промежуточные» и «резко отличающиеся» от тех, которые в рамках эталонной матрицы признаны аномальными (нетипичными). Для такого разделения необходимо автоматическое присвоение меток на основе анализа ошибок реконструкции АК. Процесс обучения начинается с момента появления у пользователя нового

типа активности, например, при первом открытии новой вкладки. С этого момента начинается накопление пятиминутных интервалов до достижения необходимого объема данных, пригодного для дальнейшего обучения.

Пусть входные данные описываются матрицей признаков $D \in \mathbb{R}^{T \times N}$, где: T – количество объектов, N – количество признаков. Требуется автоматически присвоить каждому объекту одну из трёх меток: 0, 1 или 2, отражающих уровень «сходство с эталоном».

С этой целью на первом шаге для стабилизации диапазонов изменения признаков и подготовки данных к обучению АК для каждого признака $j \in \{1, \dots, N\}$ и каждого объекта данные $i \in \{1, \dots, T\}$ нормализуются с помощью преобразования вида

$$x_{i,j}^{\text{norm}} = \frac{x_{i,j} - \min(x_{:,j})}{\max(x_{:,j}) - \min(x_{:,j})},$$

где $x_{:,j}$ – столбец всех значений признака j ; $x_{i,j}^{\text{norm}} \in [0,1]$.

На втором шаге, в режиме обучения АК, восстанавливаются нормальные/нетипичные объекты, так чтобы аномальные давали высокую ошибку реконструкции путем вычисления функции потерь $\mathcal{L}(x, \hat{x}) = \frac{1}{N} \sum_{j=1}^N (x_j^{\text{norm}} - \hat{x}_j^{\text{norm}})^2$. В каче-

стве обучающей выборки в режиме обучения используется сбалансированный набор, содержащий равные доли объектов разных типов (если это возможно).

На третьем шаге осуществляется прогон объектов через АК и для каждого объекта x_i вычисляется текущая ошибка реконструкции $\varepsilon_i = \frac{1}{N} \sum_{j=1}^N (x_{i,j}^{\text{norm}} - \hat{x}_{i,j}^{\text{norm}})^2$.

На четвертом шаге с целью адаптации границ присвоения меток на основе распределения ошибок реконструкции $\bar{\varepsilon} = \{\varepsilon_1, \dots, \varepsilon_T\}$ определяются пороговые уровни по перцентилям: $\varepsilon_{20} = \text{Percentile}_{20}(\bar{\varepsilon})$ и $\varepsilon_{50} = \text{Percentile}_{50}(\bar{\varepsilon})$. Здесь $\varepsilon_{20} = 20$ й перцентиль $\{\varepsilon_i\}$, $\varepsilon_{50} = 50$ й перцентиль $\{\varepsilon_i\}$.

По величине ошибки реконструкции в соответствии с правилом $y_i = \begin{cases} 0, & \varepsilon \leq \varepsilon_{20} \\ 1, & \varepsilon_{20} < \varepsilon \leq \varepsilon_{50} \\ 2, & \varepsilon_i > \varepsilon_{50} \end{cases}$ осуществляется присвоение меток.

Метки присваиваются следующим образом:

- Если ошибка реконструкции $\varepsilon \leq 20\%$ → присваивается метка 0;
- Если ошибка реконструкции $\varepsilon \in (20\%, 50\%]$ → присваивается метка 1;
- Если ошибка реконструкции $\varepsilon > 50\%$ → присваивается метка 2.

На пятом заключительном шаге с целью создания сбалансированной эталонной выборки происходит формирование эталонной матрицы D_{ref} . С этой целью выбирается одинаковое количество объектов с каждой меткой (0, 1, 2) и объединяются в эталонную матрицу $D_{\text{ref}} = D_0 \cup D_1 \cup D_2$, где $D_m = \{x_i | y_i = m\}$, $m \in \{0, 1, 2\}$.

В результате каждый объект получает метку, отражающую его уровень «нормальности» относительно обучающего автокодировщика. При дальнейшем анализе с помощью адаптивных порогов (перцентильный подход) формируется эталонная матрица. С этой целью признаки предварительно нормализуются, что делает метод универсальным для разных шкал. При работе АК было выбрано три уровня поведения пользователя: полностью нормальное, переходное и аномальное, как это показано на рис. 4.

В качестве примера на Рис. 5 представлена гистограмма ошибок и границы классификации для случая, когда вместо фиксированных порогов используются перцентили: – 20-й перцентиль равный 0.152, и 50-й перцентиль равный 0.280.

Рисунок 5 иллюстрирует процесс разделения групп ошибок реконструкции для автокодировщика. Показаны метки порогов 20% и 50%. Ошибки, не превышающие порог в 20%, соответствуют нормальному поведению пользователя. Область 20-50% характеризует переходное поведение. Ошибки выше 50% соответствуют аномальным выбросам. В случае, когда формируются указанные кластерные соседства интересуют тот кластер, в котором оказалась пятиминутная выборка, сгенерированная пользователем в результате его работы. В соответствии с введенной терминологией интересует сколько и какие события оказались в соответствующем кластере: нормальные, переходные, аномальные.




Рис. 4. Трехуровневая кластеризация аномального поведения на выходе АК




Рис. 5. Гистограмма ошибок и границы классификации

Этап 5. Поведенческий профиль

Для того, чтобы принимать решение при построении поведенческого профиля, используя для этих целей алгоритмы

кластерного соседства, введенные уровни аномальности поведения пользователя должны быть представлены в эталонной матрице. Под «Кластерным соседством» понимается оценка того какие события соседствуют друг другу, т.е. располагаются в одном кластере для заданного пространства атрибутов. Обычно эта процедура осуществляется с помощью кластеризации. Учитывая большую размерность пространства данных, которая определяется количеством атрибутов предлагается осуществлять кластеризацию в следующей последовательности. Процедура анализа кластерного соседства осуществляется в следующей последовательности.

На шаге 1 формируются все возможные комбинации N анализируемых атрибутов в различных комбинациях. Пусть $x \in \mathbb{R}^N$ - нормализованный вектор признаков пятиминутного интервала. Обозначим через K – минимальное количество атрибутов в комбинации (например, от 3 и до 10). Комбинации таких атрибутов легко и быстро вычисляются. В результате формируются бутстреппы (bootstrap) с различными пространствами, сформированными из таких комбинаций атрибутов. Суть бутстрэпа заключается в том, что на основе одной исходной выборки формируют несколько новых обучающих выборок, случайным образом выбирая элементы и копируя их в новую выборку (в прежней они остаются, не удаляются).

Затем эта операция повторяется по заданному размеру новой выборки. В результате формируется новая обучающая выборка, состоящая из элементов исходной с некоторыми повторениями. Множество всех возможных комбинаций атрибутов из A , длины от K до $K + M$ может быть описано соотношением

$$C = \bigcup_{r=K}^{K+M} C_r = \bigcup_{r=K}^{K+M} \{C \subseteq A \mid |C| = r\}, \quad \text{где}$$

$C_r = \{C \subseteq A \mid |C| = r\}$ - множество всех комбинаций длины r .

Каждая комбинация C из r атрибутов ($K \leq r \leq K + M$) может быть представлена либо в виде множества индексов (например, комбинация $\{a_1, a_3, a_4\}$ представляется как $\{1, 3, 4\}$), либо как битовая маска длины N – вектор $b \in \{0, 1\}^N$, где $b_i = 1$, если атрибут a_i включен в комбинацию, в противном случае (при $b_i = 0$) атрибут в комбинацию не включен.

На шаге 2 выполняется кластеризация по каждой комбинации атрибутов. С этой целью для каждого множества C всех комбинаций атрибутов из этапа 1 в полученном пространстве $D \in \mathbb{R}^{T \times N}$ производится кластерный анализ. Здесь $D \in \mathbb{R}^{T \times N}$ – исходная таблица данных, состоящая из T строк (объектов) и N столбцов (атрибутов).

Кластерный анализ позволяет упорядочить результаты прогнозирования, выделяя в исходном массиве данных группы объектов со схожими характеристиками. Такая группировка снижает сложность дальнейшего анализа и позволяет работать не с отдельными наблюдениями, а с компактным набором однородных сегментов. В отличие от задач классификации, кластеризация не опирается на заранее заданную целевую переменную: структура данных выявляется на основе выбранного пространства признаков, а число кластеров заранее может быть неизвестно и подбирается в зависимости от цели исследования и качества разбиения. В рас-

сматриваемой постановке набор признаков определяется исходной таблицей, содержащей T строк (объектов) и N столбцов (атрибутов).

Для выбранного алгоритма кластеризации (например, для алгоритма k-means) ставится в соответствие $k \in \{2, 3, 4, 5\}$ кластеров. С этой целью для каждой комбинации атрибутов $C \in \mathcal{C}$, где $C = \{a_{i_1}, a_{i_2}, \dots, a_{i_r}\}$ определяется подматрица данных $D_C = D[:, C] \in \mathbb{R}^{T \times r}$. Поскольку для алгоритма k-means количество кластеров k задано заранее, то необходимо разделить данные на кластеры таким образом, чтобы минимизировать полную сумму квадратов расстояния от данной точки до центра кластера, к которому она принадлежит.

Для решения задачи кластеризации необходимо построить множество $C = \{c_1, c_2, \dots, c_g\}$, где c_k – кластер, содержащий похожие друг на друга атрибуты $c_k = \{i_j, i_p \mid i_j \in I, i_p \in I \text{ и } d(i_j, i_p) < \sigma\}$, где $d(i_j, i_p)$ – мера близости между атрибутами; σ – заданное расстояние между атрибутами для включения их в один кластер. Для каждого подмножества C и параметра кластеризации $k \in \{2, 3, 4, 5\}$ используют итеративный алгоритм $KMeans_k(D_C) \rightarrow ClusterLabels_{C,k} \in \{1, \dots, k\}^T$. Объект x_i попадает в кластер $K_{C,k}(x_i)$ и определяется его кластерное окружение $G_{C,k}(x_i) = \{x_j \mid K_{C,k}(x_j) = K_{C,k}(x_i)\}$.

Цель кластеризации состоит в таком разбиении множества объектов, при котором минимизируется суммарная величина квадратов расстояний от каждой точки до центра того кластера, к которому она отнесена. Для этого, как правило, используется итеративный алгоритм:

1. Выбор k произвольных исходных центров $C = \{c_i\}$,

$$\text{где } c_i = \frac{\sum_{j=1}^d u_{ij} m_j}{\sum_{j=1}^d u_{ij}}, \quad c_i = \frac{\sum_{j=1}^d u_{ij} m_j}{\sum_{j=1}^d u_{ij}}, \quad \text{а } M = \{m_j\} - \text{множество}$$

данных;

2. Разбиение всех объектов на k групп, наиболее близких к одному из центров $U = \{u_{ij}\}$, где

$$u_{ij} = \begin{cases} 1 \text{ при } d(m_j, c_i) = \min_{1 \leq k \leq c} d(m_j, c_k) \\ 0 \text{ иначе} \end{cases}$$

$$u_{ij} = \begin{cases} 1, \text{ при } d(m_j, c_i) = \min_{1 \leq k \leq c} d(m_j, c_k) \\ 0, \text{ иначе} \end{cases}$$

3. Вычисление новых центров кластеров, пока центры не перестанут меняться, то есть пока решение не будет удовлетворять целевой функции $J(M, U, C) = \sum_{i=1}^c \sum_{j=1}^d u_{ij} d_A^2(m_j, c_i)$

На шаге 3, в рамках полученных кластеров формируются данные о соседстве аномалий и нормальных события, или соседстве переходных событий. При поступлении новой информации в виде нового вектора $x \in \mathbb{R}^N$ – объект с N признаками

из очередного пяти минутного интервала формируется текущее кластерное пространство комбинаций атрибутов $\mathcal{C}$ из Этапа 1. Используя кластерные модели (центроиды) из Этапа 2 для каждой пары (C, k) $\mu_1, \dots, \mu_k \in \mathbb{R}^r$ – центроиды кластеров, полученные на подпространстве $\mathcal{C}$ определим для каждой комбинации атрибутов $C \in \mathcal{C}$ и каждого $k \in \{2, 3, 4, 5\}$ номер кластера, в которые попадает объект X . Кластер для объекта X определяется как $\hat{y}_{C,k} = \arg \min_{j \in \{1, \dots, k\}} \|x_C - \mu_j\|^2$, где $x_C \in \mathbb{R}^r$ – вектор, соответствующий подмножеству атрибутов $C \subseteq \{1, \dots, N\}$. В результате можно узнать с какими типами событий (кластерами) соседствует новое наблюдение.

На шаге 4 осуществляется анализ состава кластера и вычисление распределения меток среди соседей. С этой целью для каждого объекта X_i , комбинации C , и значения k определяется кластер G , в который он попал и рассчитывается доля объектов с каждой меткой $y_i \in \{0, 1, 2\}$, $i = 1, \dots, T$ в этом кластере. В результате кластеризации для каждой комбинации C и каждого k , каждому объекту сопоставлен номер кластера $\hat{y}_i^{C,k}$ и вычисляется матрица процентного состава соседей (p_0, p_1, p_2) среди объектов в том же кластере, что и X_i .

Тогда доля объектов с меткой $m \in \{0, 1, 2\}$ в кластере G для объекта X_i оценивается соотношением

$$p_{C,k}^{(m)}(x_i) = \frac{1}{|G_{C,k}(x_i)|} \sum_{x_j \in G_{C,k}(x_i)} \mathbb{I}[y_j = m], \text{ где } \mathbb{I} - \text{индикаторная функция; } G_{C,k}(x_i) = \{x_j | \hat{y}_j^{C,k} = \hat{y}_i^{C,k}\} - \text{множество}$$

объектов в том же кластере, что и X_i ; $y_j \in \{0, 1, 2\}$ – истинная метка объекта X_j .

Поскольку таких пространств будет десятки тысяч, можно получить пространственную область поведенческого профиля, каждая точка которой будет отражать процент соседства с событиями определённого типа. Итоговая картина представляет собой поведенческий профиль поскольку будет характеризовать поведенческие особенности события.

На шаге 5 производится визуализация кластерных пространств. С этой целью для каждой пары (C, k) выполняется 2D-проекция пространства с помощью ПО (PCA / t-SNE / UMAP), где каждая точка $x_i^C \in \mathbb{R}^r$ характеризует объект в подпространстве признаков $\mathcal{C}$ а её 2D-проекция: $z_i = \text{Proj}_2(x_i^C)$, $z_i \in \mathbb{R}^2$ её координаты. Результат проекции характеризуются цветом в пространстве $\text{RGB}_i = (p_0, p_1, p_2)$. Для каждой комбинации признаков $\mathcal{C}$ и значения k необходимо:

- Построить двухмерную проекцию подпространства признаков $D_C \in \mathbb{R}^{T \times r}$ с помощью PCA, t-SNE или UMAP;
- Визуализировать на полученной 2D-плоскости каждый объект в виде точки, так что для каждой пары (C, k) формируется серия 2D-проекций (рис. 6).

Каждая точка проекции характеризует объект. Проекции помогают понять геометрию кластеров, а также проверить,

насколько логично разделяются объекты при разных k . Цвет точки $= (p_0, p_1, p_2)$, где p_0 – красный; p_1 – зелёный; p_2 – синий цвет точки характеризует номер кластера (от 0 до $k-1$), в который объект попал при разбиении с данным значением k в k-means. Например, для $k=3$, кластер 0 – красный, кластер 1 – зелёный, кластер 2 – жёлтый.



Рис. 6. Разбиение эталонной матрицы по типам на мета-кластеры

В результате кластерного анализа для каждого объекта определяется множество кластерных меток по всем (C, k) и проценты соседей по меткам (бутстреп-признаки).

Графическое представление кластерных пространств

Для каждого «нового объекта» после кластеризации (по комбинациям атрибутов) формируется множество признаков, отражающих его окружение (например, вектор частот меток в кластерах). В результате кластерного анализа для каждого объекта x формируется множество комбинаций признаков $\mathcal{C}$. Для каждой комбинации признаков $\mathcal{C}$ и каждого k , формируется вектор $f_{C,k}(x) = (p_0^{C,k}, p_1^{C,k}, p_2^{C,k})$. Совокупность подобных векторов формирует «отпечаток» (signature) объекта: $F(x) = \{f_{C,k}(x) | C \in \mathcal{C}, k \in \{2, 3, 4, 5\}\}$. Поскольку аналогичные множества признаков имеются и у эталонных объектов/классов то сравнивая оба множества принимается решение «насколько "похож" новый объект на эталон по структуре кластерных соседств? Для сравнения множеств между используются метрики расстояний между множествами векторов. Каждое множество $F(x)$ интерпретируется как распределение точек в 3D-пространстве (по p_0, p_1, p_2) и можно измерить расстояние до эталонного множества F_{ref} , используя например среднее попарное расстояние между точками

$\text{Dist}(x, x') = \frac{1}{|F(x)| \cdot |F(x')|} \sum_{u \in F(x)} \sum_{v \in F(x')} \|u - v\|_2$.

Для оценки степени сходства текущего поведения с аномальными шаблонами может быть использована метрика расстояния между многомерными векторами, например евклидова

$$S(x_i) = \min_{x_r \in \mathcal{F}_{\text{аном}}} \sqrt{\sum_{C,k} \sum_{m=0}^2 (p_{C,k}^{(m)}(x_i) - p_{C,k}^{(m)}(x_r))^2} \text{ или косинусное сходство}$$

$$\text{Sim}_{\cos}(x_i, x_r) = \frac{\langle \mathcal{F}(x_i), \mathcal{F}(x_r) \rangle}{\|\mathcal{F}(x_i)\| \cdot \|\mathcal{F}(x_r)\|}$$

Помимо расстояния между точками можно оценить плотность объектов в этих множествах по каждой из трёх меток $\{0,1,2\}$ в проекциях. Для этого можно использовать различные способы оценки плотности. Например, рассмотрев каждую точку $f_{c,k}(x) = (p_0, p_1, p_2)$ как 3D-точку можно построить оценку плотности по каждой из проекций p_0, p_1, p_2 .

Метрика расстояния позволяет оценить, насколько текущее поведение пользователя близко по структуре к ранее выявленным аномальным сценариям. Если её значение оказывается высоким, это может свидетельствовать о возрастании вероятности угрозы, связанной с действиями пользователя информационной системы [7]. Существенным преимуществом такого показателя является возможность фиксировать потенциально опасные состояния даже в тех случаях, когда ошибка реконструкции автокодировщика не указывает на явную аномалию. Кроме того, использование метрики расстояния позволяет ранжировать наблюдаемые события по степени риска — от общего подозрительного поведения до действий, имеющих выраженное сходство с инсайдерскими или вредоносными сценариями.

Введённые метрики отклонения от эталонного профиля могут использоваться при принятии решений в различных формах: как плотностные характеристики по отдельным классам, как набор признаков или как расстояния, применяемые для отбора и фильтрации аномалий. При этом наблюдение за пользователем строится на последовательной фиксации событий его активности в виде журналов. Из логов извлекаются атрибуты, преобразуемые в векторное представление, после чего данные агрегируются в пятиминутные интервалы, внутри которых определяются кластерные соседства. Это обеспечивает возможность непрерывного формирования поведенческих профилей пользователей и последующего отслеживания их изменений в процессе функционирования системы.

4 Выводы

Разработана обобщенная структура алгоритма обнаружения редкого аномального поведения пользователя информационных систем, состоящая из пяти этапов. Для обнаружения аномальной активности пользователей кластерное представление нового объекта сравнивается с эталонными объектами по метрике сходства, что позволяет оценить, насколько поведение пользователя похоже на ранее зафиксированные аномалии.

Введенные сравнительные метрики оценки отклонения от эталона можно использовать для принятия решения. Это могут быть плотностные профили по каждому классу, признаки или метрики расстояний для отбора или фильтрации аномалий. Фиксируя текущий профиль нормального или аномального функционирования, можно наблюдать за сотрудником (пользователем информационной системы) и каждый раз, когда он воспроизводит какие-то события фиксировать их в виде набора логов. Из логов извлекаются атрибуты, формируется вектор, из которого после агрегирования формируются 5-минутные интервалы, в рамках которых формируются кластерные соседства. В результате в процессе работы системы можно непрерывно получать поведенческие профили для каждого пользователя и отслеживать их характеристики.

Литература

1. Rida Nasir и др. Behavioral Based Insider Threat Detection Using Deep Learning // IEEE Access. 2021.
2. Miguel Villarreal-Vasquez и др. Hunting for Insider Threats Using LSTM-Based Anomaly Detection // IEEE TDSC. 2023.
3. Simon Bertrand и др. Unsupervised User-Based Insider Threat Detection Using BGMM // PST. 2023.
4. Taher Al-Shehari и др. Insider Threat Detection Using Isolation Forest // IEEE Access. 2023.
5. Шелухин О. И. Анализ методов обнаружения редкой аномальной активности пользователей информационных систем // Инженерный вестник Дона. 2026. № 1.
6. Xiao H., Zhang W., Lu H. Unveiling Shadows: A Comprehensive Framework for Insider Threat Detection Based on Statistical and Sequential Analysis // J. Inf. Secur. Appl. 2023. Vol. 75. DOI: 10.1016/j.jisa.2023.103582.
7. Буйневич М. В., Власов Д. С., Моисеенко Г. Ю. Комбинирование способов выявления инсайдеров больших информационных систем // Вопросы кибербезопасности. 2024. № 3(61). С. 2-13.
8. Буйневич М. В., Власов Д. С., Моисеенко Г. Ю. Повышение «устойчивости» регламентов деятельности как способ противодействия неумышленному инсайдингу // Вопросы кибербезопасности. 2024. № 6(64). С. 108-116.
9. Sridevi D. и др. ML and DL Techniques for Insider Threats // IC-CSAI. 2023.
10. Gayathri R. G. и др. Hybrid DL Model with SPCAGAN // arXiv. 2022.
11. Zewdie M. и др. DNN for Insider Threats and Social Engineering // ICECET. 2024.
12. Erramilli V. How Salesforce Helps Protect You from Insider Threats // Salesforce Engineering. 2023. Режим доступа: <https://engineering.salesforce.com/how-salesforce-helps-protect-you-from-insider-threats-5f9ae8b0e55d>
13. Шелухин О. И., Осин А. В., Хализев К. А. Обнаружение аномальной активности пользователей информационной системы на основе анализа кластерных соседств // Материалы 34-й научно-технической конференции «Методы и технические средства обеспечения безопасности информации». Санкт-Петербург, 2025. № 34. С. 11-14.
14. Шелухин О. И., Зегжеда Д. П., Раковский Д. И., Самарин Н. Н., Александрова Е. Б. Интеллектуальные технологии информационной безопасности. Москва: Горячая линия – Телеком, 2023. 384 с.
15. Шелухин О. И., Гармашев А. В. Обнаружение аномальных выбросов телекоммуникационного трафика методами дискретного вейвлет-анализа // Электромагнитные волны и электронные системы. 2012. Т. 17, № 2. С. 15-26. EDN OYMAQX.
16. Шелухин О. И., Антонян А. А. Анализ изменений фрактальных свойств телекоммуникационного трафика вызванных аномальными вторжениями // T-Comm: Телекоммуникации и транспорт. 2014. Т. 8, № 6. С. 61-64. EDN SGWEGX.
17. Шелухин О. И., Осин А. В., Костин Д. В. Мониторинг и диагностика аномальных состояний компьютерной сети на основе изучения "исторических данных" // T-Comm: Телекоммуникации и транспорт. 2020. Т. 14, № 4. С. 23-30. DOI 10.36724/2072-8735-2020-14-4-23-30. EDN AQKPYX.
18. Шелухин О. И., Симонян А. Г., Ванюшина А. В. Формирование исходных данных и анализ программного обеспечения для классификации приложений трафика методом машинного обучения // T-Comm: Телекоммуникации и транспорт. 2017. Т. 11, № 1. С. 67-72. EDN YGIYBV.
19. Шелухин О. И., Раковский Д. И. Бинарная классификация многоатрибутных размеченных аномальных событий компьютерных систем с помощью алгоритма SVDD // Научные исследования в космических исследованиях Земли. 2021. Т. 13, № 2. С. 74-84. DOI 10.36724/2409-5419-2021-13-2-74-84. EDN JBAPWV.
20. Хализев К. А., Осин А. В. Прогнозирование редких событий на основе анализа графлетов взаимодействия в социальных сетях // Инженерный вестник Дона. 2025. № 4(124). С. 336-348. EDN QDKFMF.

DETECTING RARE USER BEHAVIOR ANOMALIES IN INFORMATION SYSTEMS WITH MACHINE LEARNING

Oleg. I. Sheluhin, *Moscow Technical University of Communications and Informatics, Moscow, Russia, sheluhin@mail.ru*
Andrey V. Osin, *Moscow Technical University of Communications and Informatics, Moscow, Russia, a.v.osin@mtuci.ru*

Abstract

Aim of the study: to improve the effectiveness of countering insider threats in information systems by developing an adequate model of anomalous user behavioral profiles in CRM systems using machine-learning methods, enabling the identification of potential insiders. Research methods: an analytical review of relevant scientific publications on detecting anomalous user activity in information systems; behavioral analysis combined with machine-learning and deep-learning algorithms, which opens new opportunities for the early detection of insider threats. Results: a generalized algorithm for detecting rare anomalous user behavior in information systems has been developed. It is shown how machine-learning techniques can be used to build a reference repository of clustered patterns representing anomalous objects. To detect anomalous user activity, it is proposed to compare the cluster-based representation of a new object with reference patterns using a similarity metric, which makes it possible to assess the extent to which a user's behavior resembles previously recorded anomalies. Scientific novelty: the novelty of the work lies in an original approach to countering rare anomalous user activity in information systems based on comparing typical normal behavioral profiles with insider behavioral profiles using data mining and intelligent data analysis methods.

Keywords: *information systems, insider, anomalous activity, behavioral profile, cluster neighborhody.*

References

- [1] R. Nasir, M. Afzal, R. Latif, and W. Iqbal, "Behavioral Based Insider Threat Detection Using Deep Learning," *IEEE Access*, 2021, vol. 9, pp. 143266-143274, doi: 10.1109/ACCESS.2021.3118297.
- [2] M. Villarreal-Vasquez, G. Modelo-Howard, S. Dube, and B. Bhargava, "Hunting for Insider Threats Using LSTM-Based Anomaly Detection," *IEEE Trans. Dependable Secure Comput.*, 2023, vol. 20, no. 1, pp. 451-462, doi: 10.1109/TDSC.2021.3135639.
- [3] S. Bertrand, J. Desharnais, and N. Tawbi, "Unsupervised User-Based Insider Threat Detection Using Bayesian Gaussian Mixture Models," in *Proc. Privacy, Security and Trust Conf. (PST)*, 2023, pp. 1-10, doi: 10.1109/PST58708.2023.10320169.
- [4] T. Al-Shehari, M. S. Al-Razgan, T. Alfakih, R. A. Alsowail, and S. Pandiaraj, "Insider Threat Detection Model Using Anomaly-Based Isolation Forest Algorithm," *IEEE Access*, 2023, vol. 11, pp. 118170-118185, doi: 10.1109/ACCESS.2023.3326750.
- [5] O. I. Sheluhin, "Analysis of Methods for Detecting Rare Anomalous Activity of Information-System Users," *Engineering Bulletin of the Don*, 2026, no. 1, Art. 10690. [Online]. Available: <https://www.ivdon.ru/ru/magazine/archive/n1y2026/10690>. Accessed: Feb. 1, 2026.
- [6] H. Xiao, W. Zhang, and H. Lu, "Unveiling Shadows: A Comprehensive Framework for Insider Threat Detection Based on Statistical and Sequential Analysis," *Computers & Security*, 2024, vol. 138, Art. 103665, doi: 10.1016/j.cose.2023.103665.
- [7] M. V. Buinevich, D. S. Vlasov, and G. Yu. Moiseenko, "Combining Methods for Identifying Insiders in Large Information Systems," *Voprosy Kiberbezopasnosti*, 2024, no. 3(61), pp. 2-13.
- [8] M. V. Buinevich, D. S. Vlasov, and G. Yu. Moiseenko, "Increasing the 'Resilience' of Activity Regulations as a Method to Counter Unintentional Insider Threats," *Voprosy Kiberbezopasnosti*, 2024, no. 6(64), pp. 108-116.
- [9] D. Sridevi, L. Kannagi, G. Vivekanandan, and S. Revathi, "Detecting Insider Threats in Cybersecurity Using Machine Learning and Deep Learning Techniques," in *Proc. Int. Conf. on Communication, Security and Artificial Intelligence (ICCSAI)*, Greater Noida, India, 2023, pp. 871-875, doi: 10.1109/ICCSAI59366.2023.10397460.
- [10] R. G. Gayathri, A. Sajjanhar, and Y. Xiang, "Hybrid Deep Learning Model using SPCAGAN Augmentation for Insider Threat Analysis," *arXiv:2203.02855*, 2022, doi: 10.48550/arXiv.2203.02855.
- [11] M. Zewdie, S. Yigezu, and A. Limenih, "Deep Neural Networks for Detecting Insider Threats and Social Engineering Attacks," in *Proc. 2nd Int. Conf. on Electrical, Computer and Energy Technologies (ICECET)*, 2024, pp. 1-8, doi: 10.1109/ICECET61485.2024.10698519.
- [12] V. Erramilli, "How Salesforce Helps Protect You From Insider Threats," *Salesforce Engineering Blog*, Nov. 14, 2019. [Online]. Available: <https://engineering.salesforce.com/how-salesforce-helps-protect-you-from-insider-threats-5f9ae8b0e55d/>. Accessed: Feb. 1, 2026.
- [13] O. I. Sheluhin, A. V. Osin, and K. A. Khalizev, "Detection of Anomalous User Activity in an Information System Based on Cluster Neighborhood Analysis," in *Proc. 34th Sci-Tech. Conf. "Methods and Technical Means of Information Security"*, St. Petersburg, Russia, 2025, no. 34, pp. 11-14.
- [14] O. I. Sheluhin, D. P. Zegzhda, D. I. Rakovskiy, N. N. Samarin, and E. B. Aleksandrova, *Intelligent Information Security Technologies*. Moscow, Russia: Goryachaya Liniya-Telecom, 2023, 384 p.
- [15] O. I. Sheluhin and A. V. Garmashev, "Detection of Anomalous Outliers in Telecommunication Traffic Using Discrete Wavelet Analysis Methods," *Elektromagnitnye Volny i Elektronnnye Sistemy*, vol. 17, no. 2, pp. 15-26, 2012.
- [16] O. I. Sheluhin and A. A. Antonyan, "Analysis of Changes in the Fractal Properties of Telecommunication Traffic Caused by Anomalous Intrusions," *T-Comm*, vol. 8, no. 6, pp. 61-64, 2014.
- [17] O. I. Sheluhin, A. V. Osin, and D. V. Kostin, "Monitoring and Diagnosis of Abnormal States of a Computer Network Based on the Study of 'Historical Data'," *T-Comm*, vol. 14, no. 4, pp. 23-30, 2020, doi: 10.36724/2072-8735-2020-14-4-23-30.
- [18] O. I. Sheluhin, A. G. Simonyan, and A. V. Vanyushina, "Formation of Source Data and Analysis of Software for Traffic Application Classification Using Machine Learning," *T-Comm*, vol. 11, no. 1, pp. 67-72, 2017.
- [19] O. I. Sheluhin and D. I. Rakovskiy, "Binary Classification of Multi-Attribute Labeled Anomalous Events in Computer Systems Using the SVDD Algorithm," *High Technologies in Earth Space Research*, vol. 13, no. 2, pp. 74-84, 2021, doi: 10.36724/2409-5419-2021-13-2-74-84.
- [20] K. A. Khalizev and A. V. Osin, "Prediction of Rare Events Based on the Analysis of Interaction Graphlets in Social Networks," *Inzhenernyi Vestnik Dona*, no. 4(124), pp. 336-348, 2025.

АНАЛИЗ СТАТУСА МАРШРУТНОЙ СИСТЕМЫ ГОРОДСКОГО ПАССАЖИРСКОГО ТРАНСПОРТА ОБЩЕГО ПОЛЬЗОВАНИЯ

DOI: 10.36724/2072-8735-2026-20-5-39-48

Manuscript received 30 January 2026;

Accepted 16 March 2026

Фадюшин Алексей Александрович,
Тюменский индустриальный университет,
г. Тюмень, Россия, fadyush72@gmail.com

Петров Артур Игоревич,
Тюменский индустриальный университет,
г. Тюмень, Россия, artigpetrov@yandex.ru

Лихайрова Евгения Владимировна,
Тюменский индустриальный университет,
г. Тюмень, Россия, lihajrovaev@tyuiu.ru

Шепелёв Владимир Дмитриевич,
Южно-Уральский государственный университет
(национальный исследовательский университет),
г. Челябинск, Россия, shepelevvd@susu.ru

Исследование выполнено за счет гранта Российского
научного фонда № 24-79-00192 "Цифровой двойник
городского пассажирского транспорта общего
пользования", <https://rscf.ru/project/24-79-00192/>

Ключевые слова: городской пассажирский транспорт
общего пользования, маршрутная сеть,
пассажиропоток, транспортное моделирование,
цифровой двойник

В статье представлены результаты исследований статуса маршрутной системы городского пассажирского транспорта общего пользования (ПТОП) крупного российского города Тюмени (население 872 тыс. чел.), представленного одним видом общественного транспорта – автобусным. Цель исследования – идентификация возможного потенциала автобусного транспорта в качестве основного для осуществления транспортных передвижений горожан и поиск путей совершенствования маршрутной системы пассажирских перевозок Тюмени с использованием ПТОП. Особенно актуально данное исследование в условиях активного роста индивидуальной автомобилизации, острого дефицита пропускной способности улично-дорожной сети и потенциально ожидаемого муниципальной властью в обозримое время транспортного коллапса. Основное внимание при этом уделено идентификации специфики маршрутной сети ПТОП, статистическому описанию набора основных характеристик совокупности автобусных маршрутов Тюмени, кластерному анализу и дифференциации маршрутов по группам с учетом набора характерных признаков. Установлено, что совокупность автобусных маршрутов Тюмени весьма неоднородна и может быть дифференцирована на четыре группы маршрутов. Это важный вывод, позволяющий аргументировать возможные управленческие действия по реформированию сети маршрутов ПТОП крупного российского города, направленные на повышение эффективности всей муниципальной транспортной системы.

Информация об авторах:

Фадюшин Алексей Александрович, Тюменский индустриальный университет, доцент кафедры "Эксплуатация автомобильного транспорта", канд. техн. наук, г. Тюмень, Россия, ORCID 0000-0001-7276-431

Петров Артур Игоревич, Тюменский индустриальный университет, доцент кафедры "Эксплуатация автомобильного транспорта", канд. техн. наук, доцент, г. Тюмень, Россия, ORCID 0000-0003-2634-0567

Лихайрова Евгения Владимировна, Тюменский индустриальный университет, аспирант кафедры "Эксплуатация автомобильного транспорта", г. Тюмень, Россия.

Шепелёв Владимир Дмитриевич, Южно-Уральский государственный университет (национальный исследовательский университет), доцент Переводной инженерной школы двигателестроения и специальной техники "Сердце Урала", канд. техн. наук, доцент. ORCID 0000-0002-1143-2031

Для цитирования:

Фадюшин А.А., Петров А.И., Лихайрова Е.В., Шепелёв В.Д. Анализ статуса маршрутной системы городского пассажирского транспорта общего пользования / Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 39-48.

For citation:

A.A. Fadyushin, A.I. Petrov, E.V. Lihayrova, V.D. Shepelev, "Analysis of the status of the route system of public urban passenger transport," T-Comm, 2026, vol. 20, no. 5, pp. 39-48. (in Russian)

Введение

Опережающий, по сравнению с развитием улично-дорожной сети (УДС) рост автомобилизации во всем мире является одним из самых серьезных вызовов урбанизации [1]. Россия не является исключением из этого общемирового тренда. Резервы пропускной способности УДС крупных российских городов практически исчерпаны. В этой связи необходимо констатировать, что кардинальное улучшение транспортной системы города возможно на основе смены парадигмы восприятия городским населением достоинств и недостатков двух важнейших типов обеспечения мобильности городского населения – с использованием индивидуального автомобильного транспорта (ИАТ) и пассажирского транспорта общего пользования (ПТОП). Переориентация городских жителей на использование услуг ПТОП возможна при качественном улучшении состояния системы городского общественного транспорта (ГОТ) посредством использования инновационных практик его развития. Для несовершенной системы ПТОП характерны неоправданно высокие затраты всех видов (ресурсные, временные, финансовые и т.п.) связанные с обеспечением перемещения людей в пространстве городской территории. Анализируя возможности совершенствования системы ПТОП, отметим, что значительные резервы ее улучшения заключаются в поиске оптимальных вариантов маршрутной системы ГОТ [2] и оптимизации распределения ресурса ПТОП между регулярными маршрутами ГОТ. Качество маршрутной системы ПТОП является важнейшим фактором, влияющим на социально-экономические аспекты функционирования города [3]. В то же время надо четко понимать, что маршрутная система ПТОП всегда является производной от степени развитости УДС города, обобщенного качества городской дорожно-транспортной инфраструктуры [4].

Целью данного исследования является детализированный анализ (по состоянию на 2025 г.) статуса маршрутной системы ПТОП крупного российского города Тюмени и идентификация потенциала ГОТ в качестве основного вида осуществления транспортных передвижений горожан.

Анализ состояния вопроса

Анализ ранее проведенных исследований свидетельствует, что модернизация и совершенствование дорожно-транспортной инфраструктуры города способствует снижению транспортных заторов и повышению качества транспортных услуг [2].

Одним из самых значимых аспектов сложности развития городской системы ПТОП заключается в изменении эмоционально-практического отношения людей к личному автомобилю и его каждодневному использованию. Организационно-управленческие меры по демотивации использования личных автомобилей (платное парковочное пространство, платные автомобильные дороги) стимулируют городских жителей к приоритетному пользованию услугами ГОТ [5]. Например, технология Bus Rapid Transport (BRT) позволяет повысить скорость сообщения ПТОП [6], а такое преимущество и мероприятия по ограничению использования ИАТ являются серьезными аргументами для переориентации с использования ИАТ на ПТОП.

Предоставление приоритета движению ПТОП на регулируемых перекрестках или посредством полос для маршрутных транспортных средств приводит к положительному эффекту (выигрышам в скорости и времени перемещения) для пользователей ПТОП, повышает скорость сообщения, но одновременно с этим ухудшает параметры дорожного движения для пользователей ИАТ [7]. При этом с большой вероятностью возможно изменение структуры транспортного спроса и повышение доли поездок на ПТОП [8].

Еще одной важной проблемой развития транспортной системы города является необходимость оперативной коррекции маршрутной сети городского ПТОП, связанной с постоянным изменением общей пространственной структуры расселения городских жителей.

В ходе развития городской территории необходимо совершенствовать транспортную доступность новых районов и изменять общую конфигурацию маршрутов ПТОП [9]. Продление существующих маршрутов ПТОП до новых городских районов приводит к увеличению времени рейса, а в условиях дефицита провозной способности Перевозчиков – к увеличению интервалов движения маршрутных транспортных средств и времени ожидания на остановочных пунктах потенциальными пассажирами прибытия подвижного состава ГОТ. Разумеется, увеличение длины уже существующих маршрутов ПТОП ведет к увеличению дальности поездок пассажиров и повышает удельные расходы на перевозку пассажира и в целом снижает эффективность перевозочного процесса.

Тарифообразование на ПТОП формируется с учетом положений Приказа Министерства транспорта ГОТ 20.10.2021 г. № 351 «Об утверждении Порядка определения начальной (максимальной) цены контракта ...». В частности, величина тарифа городского ПТОП основывается на расчетах максимальной себестоимости 1 км пробега подвижного состава ГОТ. В расчетах учитываются затраты на оплату труда водителей и кондукторов, затраты на топливо, горюче-смазочные материалы и прочие эксплуатационные материалы, затраты на техническое обслуживание, ремонт и амортизацию подвижного состава. Расчет себестоимости 1 км пробега проводится для разных классов транспортных средств ГОТ, что позволяет повысить точность идентификации затрат на функционирование ПТОП на разных маршрутах.

В публикации [10] отмечается, что совокупные затраты ПТОП на выполнение транспортной работы являются сводными комплексными показателями эффективности не только подобранного подвижного состава ГОТ, но и большего числа параметров состояния системы ПТОП в целом, и в частности маршрутной системы и особенностей организации движения подвижного состава ГОТ непосредственно на УДС.

В работе [11] авторы описывают многоэтапность поиска эффективных решений в сфере совершенствования городского транспортного комплекса и объясняют проблематику сложности данной задачи многокритериальностью и разнообразием целевых функций. Решение задач оптимизации эффективности ПТОП связано с поиском оптимума для целой группы критериев [12] и выбором наиболее значимых из числа возможных вариантов – весьма непростая задача.

В работе [13] отмечается, что эффективность мероприятий по совершенствованию городской транспортной системы может существенно отличаться для разных районов города и зависит от пространственного распределения транспортного

спроса. Авторы дифференцируют районы города на несколько кластеров. Это позволяет идентифицировать зависимость структуры транспортного спроса (ИАТ / ПТОП) от среднего времени в пути.

С учетом цели и результатов проведенного анализа состояния вопроса были сформулированы следующие задачи исследования:

- провести статистический анализ основных показателей, характеризующих маршрутную сеть ПТОП Тюмени;
- провести статистический анализ базовых показателей, описывающих качество обслуживания маршрутной сети ПТОП Тюмени провозными возможностями ОТ;
- сформировать цифровой двойник ПТОП Тюмени.

Статистический анализ основных показателей, характеризующих маршрутную систему ПТОП Тюмени

Решение большой по объему и сложной по причине многокритериальности задачи по идентификации состояния маршрутной системы ПТОП весьма затруднительно без создания цифровой модели исследуемой системы, в частности – модели ГОТ.

В рамках исследования были собраны данные о фактическом качестве функционирования ПТОП в крупном российском городе Тюмени (население по состоянию на 2025 г. – 872 тыс. чел.). Необходимо уточнить, что маршрутная сеть ПТОП Тюмени объединяет 116 автобусных маршрутов, на которых работают 1276 автобусов. Других видов городского пассажирского общественного транспорта в Тюмени нет (до 2009 г. в городе функционировал троллейбусный транспорт).

В базе данных представлены следующие таблицы данных (схема базы данных ER-диаграмма представлена на рис. 1):

- информация о маршрутах ПТОП Тюмени и сведения об особенностях траектории их трассы в пространстве городской территории;
- информация об остановочных пунктах маршрутной сети ПТОП Тюмени (наименование, координаты, связь с направлением движения ГОТ);
- таблица информации о маршрутах ПТОП (наименование, номер маршрута);
- таблица связей между маршрутами ПТОП и остановочными пунктами на пути следования;
- информация о перегонах между остановочными пунктами на маршрутах ПТОП (текущий остановочный пункт, следующий остановочный пункт, порядковый номер перегона, траектория движения, принадлежность маршруту ПТОП);
- расписание движения маршрутных транспортных средств (уникальные номера единиц подвижного состава, остановочных пунктов, маршрутов ПТОП и плановое время прибытия на конкретные остановочные пункты);
- информация об используемом на маршруте подвижном составе ГОТ (государственный номер транспортного средства, вместимость, тип вместимости, категория, количество сидячих мест);
- информация о связи маршрутов ПТОП с обслуживающими их пассажирскими автотранспортными предприятиями;
- информация о пассажирских автотранспортных предприятиях.

На основе предварительной обработки данных были получены дополнительные параметры маршрутной системы ГОТ Тюмени, в частности:




Рис. 1. ER-диаграмма базы данных о функционировании системы ПТОП Тюмени

- длина оборотного рейса для маршрутов ПТОП на основе пространственных координат (гистограмма распределения длин оборотных рейсов маршрутов ГОТ Тюмени представлена на рис. 2);
- длина перегонов на маршрутах ПТОП (гистограмма распределения длин перегонов маршрутов ГОТ Тюмени представлена на рис. 3);
- число маршрутов ПТОП, обслуживающихся конкретным остановочным пунктом (рис. 4);
- количество обслуживаемых остановочных пунктов конкретным маршрутом ПТОП (рис. 6).

На рисунках 2-4 и 6 представлены гистограммы, характеризующие распределения численных значений вышеуказанных параметров маршрутной системы ГОТ Тюмени.

Средняя (медианная) длина оборотного рейса маршрутов ПТОП Тюмени (рис. 2) составляет соответственно 37 (34) км. Это высокая величина для города общей площадью $\approx 491 \text{ км}^2$. По сути, это косвенное свидетельство практически полного охвата всей городской территории маршрутной сетью ПТОП.

Об этом же косвенно свидетельствует и общее число маршрутов, обслуживаемых ПТОП – 116, что превышает общепринятый норматив 1 маршрут / 10 тыс. чел. населения.




Рис. 2. Гистограмма распределения длин оборотного рейса маршрутов ПТОП Тюмени

На рис. 3 представлена гистограмма распределения длин перегонов на маршрутах ПТОП Тюмени. Средняя (медианная) длина перегона между остановочными пунктами на маршрутах ПТОП Тюмени составляет, соответственно, 690 (520) м.




Рис. 3. Гистограмма распределения длин перегонов большей части маршрутов ПТОП Тюмени

Перегоны длиной более 2,5 км составляют 1,8% от числа всех маршрутных перегонов ПТОП Тюмени и относятся к группе пригородных маршрутов. В целом это вполне соответствует общепринятой практике. Более интересны данные о длинах перегонов на городских маршрутах. 25% значений длин перегонов между остановочными пунктами ПТОП относятся к категории «Длина перегона более 730 м», что позволяет сделать вывод либо о малой связности УДС на периферии города, либо об относительном несовершенстве маршрутной сети ПТОП Тюмени.

На рис. 4 представлена гистограмма распределения числа маршрутов ПТОП, обслуживаемых конкретным остановочным пунктом (ОП).

Среднее (медианное) значение числа маршрутов ПТОП, обслуживаемых конкретным остановочным пунктом составляет соответственно 4 (2) единицы. Разумеется, для центральных районов города характерна большая концентрация обслуживаемых ОП маршрутами ПТОП.




Рис. 4. Гистограмма распределения обслуживаемых маршрутов остановочными пунктами ПТОП Тюмени

Именно в центре города локализируются ОП, относящиеся к классу транспортно-пересадочных узлов. Связано это со спецификой УДС Тюмени, сформированной исторически. УДС Тюмени представляет собой фрактал класс «краб» (рис. 5), центральной осью которого является улица Республики (до 1917 г. – ул. Царская), вокруг которой исторически в течение 4-х столетий протекал рост города.



Рис. 5. Фрактал маршрутной сети ПТОП Тюмени

В таблице 1 представлены наиболее представительные ОП ГОТ, относящиеся к классу транспортно-пересадочных узлов. Классификационный критерий выбора ОП – количество маршрутов ГОТ, обслуживаемых ОП.

Например, ОП «Завод Медоборудования» обслуживает автобусы 30 маршрутов ПТОП Тюмени (20 городских и 10 пригородных); ОП «Красно» обслуживает 28 маршрутов ПТОП Тюмени (21 городской и 7 пригородных). Четыре из пяти ОП, представленных в таблице 1, локализируются на оси

фрактала маршрутной сети ПТОП Тюмени – ул. Республики, исторически важнейшей транспортной артерии города. Единственное исключение – ОП ранга 5 (мкр. Тюменский) локализуется на улице в два шага фрактала маршрутной сети.

Таблица 1

Примеры остановочных пунктов ПТОП Тюмени, обслуживающих максимальное число маршрутов ГОТ

Наименование остановочного пункта (ОП) маршрутной сети ПТОП Тюмени	Количество маршрутов ГОТ, обслуживаемых ОП, ед.	Число рейсов, выполняемых ГОТ, проходящих через ОП, рейсов
Сквер им. Немцова	31	1184
Завод Медоборудования	30	809
Кросно	28	801
Ул. Холодильная	24	1129
мкр. Тюменский	24	1387

На рис. 6 представлена гистограмма распределения количества обслуживаемых остановочных пунктов конкретным маршрутом ПТОП (для оборотного рейса).




Рис. 6 Гистограмма распределения количества остановочных пунктов на оборотном рейсе маршрутов ПТОП Тюмени

Статистическое распределение количества остановочных пунктов (ОП) ПТОП, приходящихся на оборотный рейс маршрутов, соответствует нормальному закону. Среднее (медианное) значение данного параметра составляет соответственно 54 (55) единиц ОП.

В ходе аналитической работы также были решены следующие промежуточные задачи:

- скорректированы и удалены дубликаты типов вместимости для маршрутных транспортных средств ГОТ;
- удалены дубликаты остановочных пунктов ПТОП;
- удалены дубликаты времени движения маршрутных транспортных средств;
- объединены таблицы маршрутов, перегонов, остановочных пунктов, расписания и маршрутных транспортных средств в общую таблицу.

Основываясь на анализе базы данных маршрутной сети ПТОП Тюмени, были установлены пары ОП с возможностью прямого сообщения, без осуществления пересадки с автобуса одного маршрута на автобусы других маршрутов ГОТ.

Распределение количества ОП ПТОП, характеризующихся возможностью прямого беспересадочного сообщения представлено на рис. 7.

С целью обеспечения возможностей анализа связности всех остановочных пунктов ПТОП на маршрутах определена общая таблица рейсов, обслуживающих ОП, содержащая информацию о маршруте и пути следования, длине маршрута, предыдущем и последующем ОП, информацию об автобусе и времени прибытия.

В итоговой аналитической таблице содержится 268 тыс. строк (отправлений/прибытий от / к ОП ПТОП за сутки).




Рис. 7. Гистограмма распределения числа ОП ПТОП Тюмени с возможностью обеспечения прямого беспересадочного сообщения

В таблице 2 приведены сведения о 5 ОП маршрутной сети ГОТ Тюмени, обеспечивающих максимально возможное число связей с другими остановочными пунктами в беспересадочном сообщении.

Таблица 2

Примеры пяти остановочных пунктов ПТОП Тюмени, обеспечивающих максимальное число связей с другими остановочными пунктами в беспересадочном сообщении

Наименование остановочного пункта (ОП) маршрутной сети ПТОП Тюмени	Число связей с другими ОП в беспересадочном сообщении, ед.
Завод Медоборудования	313
мкр. Тюменский	258
Сквер Семёна Пацко	248
ЖД Вокзал	215
ул. Холодильная	209

Важную роль в описании специфики маршрутной сети ПТОП также играет такой показатель, как суточное количество рейсов маршрутных транспортных средств (ТС), обслуживающих ОП. Распределение охвата рейсов ПТОП на остановочных пунктах представлено на рис. 8.

На 33,1% от общего числа ОП маршрутной сети ПТОП совершают остановки для посадки / высадки пассажиров автобусы, выполняющие 80% рейсов. Данное распределение охвата остановочными пунктами фактически выполняемых автобусами рейсов соответствует распределению Парето.




Рис. 8. Распределение охвата рейсов ПТОП на остановочных пунктах маршрутной сети Тюмени

Необходимо отметить, что обычно данная практика соответствует радиальной конфигурации маршрутной сети ПТОП.

В базе данных о функционировании ПТОП Тюмени представлены также данные о подвижном составе ГОТ и их классах вместимости. Общие параметры подвижного состава ПТОП Тюмени представлены в таблице 3.

Таблица 3

Распределение подвижного состава ПТОП Тюмени по классам вместимости

Класс маршрутных ТС (автобусов) A_m по вместимости	Число A_m , ед.	Диапазон значений по вместимости		
		Мин. значение	Сред. значение	Макс. значение
Малый	383	17	19	39
Средний	291	39	57	77
Большой	528	53	108	115
Особо большой	74	164	184	193

Уточним, что большой и средний классы автобусов могут характеризоваться пересечением величин вместимости, так как различия в классах определяются габаритами длины, а пассажировместимость зависит от конфигурации салона, числа сидячих мест и т.п.

Исходя из координат остановочных пунктов и путей следования маршрутов ГОТ был определен коэффициент непрямолинейности трасс маршрутов $K_{непр}$. Распределение численных значений коэффициента $K_{непр}$ представлено на рис. 9.

К группе относительно приемлемых по уровню непрямолинейности ($K_{непр} < 1,5$) трасс маршрутов в городском пространстве относятся лишь 38% маршрутов ПТОП Тюмени. Это еще одно свидетельство несовершенства маршрутной системы ПТОП Тюмени. Надо отметить, что проблематика непрямолинейности трасс маршрутов во многом является следствием пространственно-географической специфики городской территории (разделение территории города на три основных части рекой и железнодорожной магистралью Транссиба), но не во всех случаях. Возможности снижения непрямолинейности трасс маршрутов ПТОП в Тюмени существуют.




Рис. 9. Гистограмма распределения численных значений коэффициента непрямолинейности маршрутов ПТОП Тюмени (учтены трассы 116 маршрутов в двух направлениях движения автобусов)

Цифровой двойник пассажирского транспорта общего пользования

Для формирования цифрового двойника ПТОП и модели транспортного предложения обычно используются технологии теории графов [14]. На основе базы данных об остановочных пунктах, маршрутной сети ГОТ, подвижном составе и расписании ПТОП формируется модель графа, состоящая из вершин (остановочные пункты и остановки маршрутов ГОТ) и ребра между вершинами. Ребра в графе делятся на несколько типов (с соответствующими параметрами или весами):

- перегон маршрута между остановочными пунктами ПТОП (параметры: время движения и длина перегона, вместимость маршрутных ТС, наименование маршрутов и пр.);
- посадка пассажиров в маршрутное ТС на остановочном пункте ГОТ (время ожидания маршрутного ТС на ОП, стоимость проезда, порядковый номер маршрутного ТС в поездке, риск отказа посадки и пр.);
- высадка пассажиров на остановочном пункте ГОТ;
- ожидание пассажиров внутри маршрутного ТС на остановочном пункте (длительность остановки, фактическая загрузка «проезжающие пассажиры» и пр.)

Например, при формировании графа маршрутной сети внутри остановочного пункта «Сквер им. Немцова» формируется 63 вершины (один центроид, 31 для «посадки» в маршрутные ТС и 31 для «высадки» из маршрутных ТС). Схематичное отображение выборочного участка графа маршрутной сети ПТОП представлено на рис. 10.




Рис. 10. Граф участка маршрутной сети городского пассажирского транспорта общего пользования

На рис. 10 для ОП-1 и для ОП-5 отсутствуют связи на посадку и посадку соответственно, так как для маршрута ПТОП № 1 ОП-1 является начальным остановочным пунктом, а для маршрута ПТОП № 2 ОП-5 является конечным.

Для формирования матриц корреспонденций и матриц затрат всех видов при моделировании транспортных потоков на графе в модель была добавлена информация о районах города. На основе метода Ball tree поиска ближайших соседей (библиотеки Scikit-learn) были определены расстояния между всеми парами транспортных районов и остановочными пунктами ПТОП. Для каждого района были определены остановочные пункты ПТОП, находящиеся в рамках транспортных районов, ограниченных окружностью радиусом 500 м и сформированы дополнительные вершины на графе. Распределение количества остановочных пунктов ПТОП для районов города представлено на рис. 11.




Рис. 11. Распределение количества ОП в транспортных районах, ограниченных окружностью радиусом 500 м

Для центральных районов города, для которых связность территории больше – характерно статистически большее количество остановочных пунктов ПТОП.

Прогнозное распределение пассажиропотоков на маршрутной сети ПТОП Тюмени может выполняться на основе использования следующего последовательного алгоритма действий:

1. Деление. Исходная матрица корреспонденций делится на N равных частей (количество итераций).
2. Оп еделение путей передвижений пассажиров ПТОП в пространстве города с использованием алгоритма Дейкстры. Для каждой корреспонденции определяется кратчайший путь следования по маршрутной сети ГОТ (по выбранному параметру, например, по времени в пути, стоимости проезда и др.).
3. Идентификация прогнозных пассажиропотоков. Объем поездок из частичной матрицы устанавливается (добавляется) для каждого ребра входящих в кратчайший путь корреспонденции.
4. Обновление параметров ребер графа маршрутной сети ГОТ. После каждого распределения частичной матрицы, параметры на ребрах графа маршрутной сети обновляются, в целях учета пассажироместимости подвижного состава ГОТ.
5. Сл ующая итерация (возвращение к пункту 2).

Другим возможным вариантом распределения пассажиропотоков на маршрутной сети ПТОП является алгоритм распределения методом Франка-Вульфа.

Кластерный анализ системы маршрутов ПТОП Тюмени

Кластерный анализ проводился на основе PCA (Principal Component Analysis) метода главных компонент. В рамках данного метода были определены две главные компоненты PC1 «Пространственные» (длина маршрута, перегонов и плотность остановочных пунктов) и PC2 «Емкость» (средняя вместимость маршрутных ТС на маршрутах).

Параметры, определяющие главные компоненты маршрутов, представлены в табл. 4.

Таблица 4

Характеристики кластеров

Характеристика маршрутов ПТОП	№ кластера маршрутов ПТОП Тюмени			
	1	2	3	4
Средняя длина маршрута за оборотный рейс, км	44	36	51	26
Среднее количество ОП за оборотный рейс, ед.	135	125	60	82
Средняя плотность ОП по длине маршрута, ОП/км	3,1	3,5	1,2	3,2
Средняя расчетная вместимость подвижного состава, пасс.мест / автобус	113	30	41	101
Количество маршрутов в кластере, ед.	33	34	13	36
Описание характерных особенностей маршрута по длине и используемого подвижного состава	Длинные маршруты; Подвижной состав большого и особо большого класса	Короткие маршруты; Подвижной состав малого и среднего класса	Длинные маршруты; Подвижной состав среднего класса	Короткие маршруты; Подвижной состав большого и особо большого класса
Примеры (номера) маршрутов ПТОП Тюмени	1д, 46, 54	43, 76, 84	10, 138, 158	1, 25, 30
Обобщенная характеристика маршрутов ПТОП Тюмени по типу	Длинные магистральные с большими объемами перевозок	Периферийные, с высокой непрямолинейностью и малыми объемами	Длинные вылетные, пригородного типа, с малыми объемами перевозок	Короткие магистральные с большими объемами перевозок

Пространственные компоненты и влияние длины оборотного рейса $L_{м.оборот}$ маршрута ПТОП на число ОП представлено на рис. 12. На рисунке представлена дифференциация маршрутов на кластеры 1-4. По величине коэффициента корреляции R можно сделать вывод о наличии статистической связи между оборотной длиной маршрута ПТОП $L_{м.оборот}$ и числом остановочных пунктов, приходящихся на оборотный рейс $N_{о,л}$.

На рис. 12 представлена также зависимость $N_{о,л} = f(L_{м.оборот})$ с дифференциацией по четырем кластерам маршрутов ПТОП Тюмени.




Рис. 12. Кластерная специфика зависимости $N_{о,л} = f(L_{м.оборот})$

На рис. 13 представлены фракталы класса «паук» ПТОП Тюмени, обобщающие трассы маршрутов вышеуказанных четырех кластеров.




Рис. 13. Фракталы класса «паук» ПТОП Тюмени, обобщающие трассы маршрутов четырех кластеров

Обсуждение и выводы

Тематика исследований, связанных с изучением особенностей закономерностей формирования маршрутных сетей

ПТОП, является весьма актуальной для самых разных стран мира [15-17]. Объясняется это как вызовами времени, так и необходимостью снижения затрат на функционирование систем пространственного перемещения горожан, особенно в кризисные времена. Особенно ярко эта проблематика проявилась в период острой фазы COVID-19 [18].

Касаясь непосредственно результатов, полученных в ходе анализа статуса маршрутной системы ПТОП Тюмени и представленных выше, необходимо отметить следующие основные выводы.

1. Степень развития маршрутной сети автобусного ПТОП города можно характеризовать как высокую. 116 маршрутов, приходящихся на город с селитебной площадью $\approx 491 \text{ км}^2$, – это достаточно высокий по значению показатель.

2. Большинство маршрутов ГОТ можно характеризовать как маршруты с избыточной длиной. Медианная длина маршрутов ПТОП Тюмени по обороту составляет $\approx 34 \text{ км}$, что для города с населением менее 1 млн. чел. представляется чрезмерно высоким показателем. Это является основной причиной высокой пространственной неравномерности распределения пассажиропотоков по длине маршрута, что в конечном итоге отрицательно влияет на эффективность функционирования системы ПТОП. Медианное число ОП, приходящихся на типичный маршрут ПТОП Тюмени – 55, что является очень высоким показателем. Это еще одно свидетельство необходимости пересмотра системы маршрутов, в частности дифференциации маршрутов на скоростные (экспрессные) длинные и высокоэффективные короткие.

3. Для маршрутов ГОТ Тюмени характерен высокий коэффициент непрямолинейности трасс. Медианное значение $K_{непр} = 1,6$. К группе относительно приемлемых по уровню непрямолинейности ($K_{непр} < 1,5$) трасс маршрутов в городском пространстве относятся лишь около 38%. Это очень невысокий, в сравнении с большинством других, сопоставимых по населению, городов. Этот факт требует немедленного пересмотра маршрутной системы ПТОП Тюмени.

4. Медианная длина перегонов на маршрутах составляет 520 м, что в целом можно характеризовать как соответствие общепринятым как в РФ, так и в мировой практике, нормативам.

5. Треть остановочных пунктов (ОП) маршрутной сети ПТОП Тюмени обслуживает 80% выполняемых автобусами рейсов. Именно это является основой для вывода о высокой степени неравномерности востребованности ОП горожанами, и, в конечном итоге, также свидетельствует о необходимости совершенствования системы маршрутов города. В центральной части города, на оси фрактала маршрутной системы ОП могут обслуживать до 24-31 маршрутов (от общего числа 116). Периферийные ОП обслуживают автобусы очень малого числа маршрутов (около 600 ОП, или более 51% от общего числа, обслуживают всего по 1-3 маршрута).

6. Кластерный анализ маршрутов ПТОП Тюмени, выполненный по признаку соответствия числа ОП длине маршрута, показал, что автобусные маршруты дифференцируются по 4 группам:

- кластер №1 – длинные маршруты, на которых используется подвижной состав большого и особо большого класса;
- кластер №2 – короткие маршруты с использованием подвижного состава малого и среднего класса;

- кластер №3 – длинные маршруты, на которых используется подвижной состав среднего класса;
- кластер №4 – короткие маршруты, для которых характерна эксплуатация подвижного состава большого и особо большого класса.

Именно маршруты 4 кластера можно отнести к системе магистральных, выполняющих основную транспортную работу по перемещению городского населения в пространстве и времени. Таких маршрутов в маршрутной системе ПТОП Тюмени всего 36 или 31% от общего числа.

7. Идентификация статуса маршрутной системы ПТОП – важнейший элемент управленческой деятельности в сфере организации транспортного обслуживания населения городов. Это начальная отправная точка для принятия важных управленческих решений, реализация которых позволит значительно улучшить транспортную систему крупного города.

В качестве заключительного обобщающего вывода необходимо констатировать, что аналогичные исследования необходимо проводить для всех городов с населением более 100 тыс. чел. Итоговым результатом подобных исследований может быть четкая аргументация важнейшего вывода о наступлении момента необходимости реформирования системы городских маршрутов ПТОП. Косвенные результаты – идентификация «болевых» аспектов такой реформы. Степень актуальности подобных исследований может варьироваться, однако важно отметить, что их значимость возрастает именно в кризисные времена, когда муниципалитеты уже не могут позволить себе дальнейшее относительно неэффективное использование бюджетных средств.

Финансирование

Исследование выполнено за счет гранта Российского научного фонда № 24-79-00192 «Цифровой двойник городского пассажирского транспорта общего пользования», <https://rscf.ru/project/24-79-00192/>

Литература

1. Morozov V.V., Morozov G.N., Shepelev V.D. Modeling the formation of a vehicle queue at urban signal-controlled intersections // T-Comm: Телекоммуникации и транспорт. 2025. Т. 19, № 3. С. 61-68. DOI: 10.36724/2072-8735-2025-19-3-61-68.
2. Petrov A.I., Zakharov D.A., Petrova D.A. Experts on Resistance to Reorganization of Structure and Technologies of Urban Mobility Provision in Russia: Challenges, Reasons, Solutions and Prospects // Automotive Experiences. 2023. Vol. 6, No. 1, pp. 38-58. DOI: 10.31603/ae.7928.
3. Bao L., Kusadokoro M., Chitose A., Chen Ch. Development of socially sustainable transport research: A bibliometric and visualization analysis // Travel Behaviour and Society. 2023. Vol. 30, pp. 60-73. DOI: 10.1016/j.tbs.2022.08.012.
4. Мухаметханов Р.И. Анализ структуры улично-дорожной сети города и ее элементов // Системные технологии. 2023. № 2(47). С. 164-169. DOI: 10.55287/22275398_2023_2_164.
5. Захаров Д.А., Чикишев Е.М., Капский Д.В., Скирковский С.В. Изменение параметров городской транспортной системы при введении платы с владельцев автомобилей за использование улично-

дорожной сети и варьировании стоимости проезда в общественном транспорте // Наука и техника. 2024. Т. 23, № 4. С. 336-344. DOI: 10.21122/2227-1031-2024-23-4-336-344.

6. Jain G.V., Jain S.S., Parida M. Evaluation of travel speed of conventional buses and bus rapid transit service in Ahmedabad city, India using geo-informatics // Journal of Public Transportation. 2022. Vol. 24. P. 100034. DOI: 10.1016/j.jpubtr.2022.100034.

7. Захаров Д.А., Писцов А.В. Анализ эффективности способов активного приоритета автобусам при проезде регулируемых перекрестков // Транспорт Урала. 2023. № 4(79). С. 90-95. DOI: 10.20291/1815-9400-2023-4-90-95.

8. Захаров Д.А., Фадюшин А.А. Изменение подвижности населения при развитии в городах инфраструктуры для общественного транспорта, велосипедистов и пешеходов // Вестник гражданских инженеров. 2020. № 5(82). С. 187-193. DOI: 10.23968/1999-5571-2020-17-5-187-193.

9. Chainikov D., Zakharov D., Kozin E., Pistsov A. Studying Spatial Unevenness of Transport Demand in Cities Using Machine Learning Methods // Applied Sciences (Switzerland). 2024. Vol. 14, No. 8. P. 3220. DOI: 10.3390/app14083220.

10. Колин А.В., Рыбаков П.В., Красильников П.А., Айсина Л.Р. Расчёт себестоимости транспортной работы на городском пассажирском наземном транспорте с использованием метода единичных расходных ставок // International Journal of Advanced Studies. 2025. Т. 15, № 1. С. 22-46. DOI: 10.12731/2227-930X-2025-15-1-326.

11. Халтурин Р.А., Карелина М.Ю. Концепция управления пассажирским транспортом в целях сбалансированного развития // T-Comm: Телекоммуникации и транспорт. 2024. Т. 18, № 8. С. 61-67. DOI: 10.36724/2072-8735-2024-18-8-61-67.

12. Амиргалиева С., Аземша С., Касымова Д., Кравченко И. Оценка эффективности оптимизации расписания движения городского пассажирского транспорта с учетом дублируемости маршрутов имитационным моделированием // Вестник Казахской академии транспорта и коммуникаций им. М. Тынышпаева. 2025. № 1(136). С. 76-87. DOI: 10.52167/1609-1817-2025-136-1-76-87.

13. Захаров Д.А. Пространственная неравномерность распределения по районам города Тюмени транспортного спроса на передвижение индивидуальным и общественным транспортом // Вестник гражданских инженеров. 2023. № 3(98). С. 114-122. DOI: 10.23968/1999-5571-2023-20-3-114-122.

14. Фадюшин А.А., Захаров Д.А., Игнатьев В.А., Шепелев В.Д. Пространственная неравномерность формирования затрат при реализации транспортных и пешеходных корреспонденций в крупном городе // T-Comm: Телекоммуникации и транспорт. 2025. Т. 19, № 6. С. 43-51. DOI: 10.36724/2072-8735-2025-19-6-43-51.

15. Yang X., Lu S., Zhao W., Zhao Z. Exploring the Characteristics of an Intra-Urban Bus Service Network: A Case Study of Shenzhen, China // ISPRS International Journal of Geo-Information. 2019. Vol. 8, No. 11. P. 486. DOI: 10.3390/ijgi8110486.

16. Cao Y., Jiang D., Wang S. Optimization for Feeder Bus Route Model Design with Station Transfer // Sustainability. 2022. Vol. 14, No. 5. P. 2780. DOI: 10.3390/su14052780.

17. Wei Y., Jiang N., Li Z., Zheng D., Chen M., Zhang M. An Improved Ant Colony Algorithm for Urban Bus Network Optimization Based on Existing Bus Routes // ISPRS International Journal of Geo-Information. 2022. Vol. 11, No. 5. P. 317. DOI: 10.3390/ijgi11050317.

18. Petrov A.I., Petrova D.A. Sustainability of Transport System of Large Russian City in the Period of COVID-19: Methods and Results of Assessment // Sustainability. 2020. Vol. 12, No. 18. P. 7644. DOI: 10.3390/su12187644.

ANALYSIS OF THE STATUS OF THE ROUTE SYSTEM OF PUBLIC URBAN PASSENGER TRANSPORT

Alexey A. Fadyushin, Industrial University of Tyumen, Tyumen, Russia, fadyush72@gmail.com

Artur I. Petrov, Industrial University of Tyumen, Tyumen, Russia, artigpetrov@yandex.ru

Evgeniya V. Lihajrova, Industrial University of Tyumen, Tyumen, Russia, lihajrovaev@tyuiu.ru

Vladimir D. Shepelev, South Ural State University (National Research University), Chelyabinsk, Russia, shepelevvd@susu.ru

Abstract

This article presents the results of a study examining the status of the public urban passenger transport (PUPT) route system in Tyumen, a large Russian city (population 872,000), which is represented by a single mode of public transport – buses. The objective of the study is to identify the potential of buses as a primary means of public transportation for city residents and to identify ways to improve Tyumen's PUPT-based passenger transportation route system. This study is particularly relevant given the rapidly growing number of private motorists, the acute shortage of road network capacity, and the potential transport collapse anticipated by municipal authorities in the foreseeable future. The study focuses on identifying the specific features of the PUPT route network, statistically describing a set of key characteristics of Tyumen's bus routes, cluster analysis, and route differentiation based on a set of characteristic features. It has been established that Tyumen's bus routes are highly heterogeneous and can be divided into four route groups. This is an important conclusion that allows us to justify possible management actions to reform the network of public transport routes in a large Russian city, aimed at increasing the efficiency of the entire municipal transport system.

Keywords: urban public passenger transport, route network, passenger flow, transport modeling, digital twin

References

- [1] V.V. Morozov, G.N. Morozov, V.D. Shepelev, "Modeling the formation of a vehicle queue at urban signal-controlled intersections," *T-Comm*. 2025. Vol. 19, No. 3, pp. 61-68. DOI: 10.36724/2072-8735-2025-19-3-61-68.
- [2] A. I. Petrov, D. A. Zakharov, D. A. Petrova, "Experts on Resistance to Reorganization of Structure and Technologies of Urban Mobility Provision in Russia: Challenges, Reasons, Solutions and Prospects," *Automotive Experiences*. 2023. Vol. 6, No. 1. pp. 38-58. DOI: 10.31603/ae.7928.
- [3] L. Bao, M. Kusadokoro, A. Chitose, and Ch. Chen, "Development of socially sustainable transport research: A bibliometric and visualization analysis," *Travel Behaviour and Society*. 2023. Vol. 30, pp. 60-73. DOI: 10.1016/j.tbs.2022.08.012.
- [4] R. I. Mukhametkhanov, "Analysis of the structure of the city's road network and its elements," *Systems technologies*. 2023. No. 2 (47), pp. 164-169. DOI: 10.55287/22275398_2023_2_164.
- [5] D. A. Zakharov, E. M. Chikishev, D. V. Kapski, S. V. Skirkovski, "Changing the Parameters of the Urban Transport System with Introduction of Fees from Car Owners for Using the Road Network and Variations in Public Transport Fare," *Science and Technique*. 2024. Vol. 23, No. 4. pp. 336-344. DOI: 10.21122/2227-1031-2024-23-4-336-344.
- [6] G. V. Jain, S. S. Jain, and M. Parida, "Evaluation of travel speed of conventional buses and bus rapid transit service in Ahmedabad city, India using geo-informatics," *Journal of Public Transportation*. 2022. Vol. 24, p. 100034. DOI: 10.1016/j.jpuptr.2022.100034.
- [7] D. A. Zakharov, A. V. Pistsov, "Analysis of the effectiveness of active priority methods for buses when passing through controlled intersections," *Transport in the Urals*. 2023. No. 4(79), pp. 90-95. DOI: 10.20291/1815-9400-2023-4-90-95.
- [8] D. A. Zakharov, A. A. Fadyushin, "Changing population mobility with the development of infrastructure for public transport, cycling and pedestrians in cities," *Civil Engineers Bulletin*. 2020. No. 5(82), pp. 187-193. DOI: 10.23968/1999-5571-2020-17-5-187-193.
- [9] D. Chainikov, D. Zakharov, E. Kozin, A. Pistsov, "Studying Spatial Unevenness of Transport Demand in Cities Using Machine Learning Methods," *Applied Sciences*. 2024. Vol. 14, No. 8, p. 3220. DOI: 10.3390/app14083220.
- [10] A. V. Kolin, P. V. Rybakov, P. A. Krasilnikov, L. R. Aisina, "Calculation of the self-cost of transportation work on ground urban transit using the unit expense rate method," *International Journal of Advanced Studies*. 2025, Vol. 15, No. 1, pp. 22-46. DOI: 10.12731/2227-930X-2025-15-1-326.
- [11] R. A. Khalturin, M. Yu. Karelina, "The concept of passenger transport management for balanced development," *T-Comm*. 2024. Vol. 18, No.8, pp. 61-67. DOI: 10.36724/2072-8735-2024-18-8-61-67.
- [12] S. Amiralieva, S. Azemsha, D. Kasymova, and I. Kravchenya, "Evaluation of the efficiency of optimization of the urban passenger transport schedule taking into account the duplication of routes by simulation modeling," *Vestn. Kaz. Akad. Transp. Kommun. im. M. Tynyshpaeva*. 2025. No. 1(136), pp. 76-87. DOI: 10.52167/1609-1817-2025-136-1-76-87.
- [13] D. A. Zakharov, "Spatial unevenness of the transport demand distribution for movement by private and public traffic transportation in the districts of the city of Tyumen," *Civil Engineers Bulletin*. 2023. No. 3(98), pp. 114-122. DOI: 10.23968/1999-5571-2020-17-5-187-193.
- [14] A. A. Fadyushin, D. A. Zakharov, V. A. Ignatiugin, V. D. Shepelev, "Spatial unevenness of costs formation in the implementation of transport and pedestrian correspondences in large city," *T-Comm*. 2025. Vol. 19, No.6, pp. 43-51. DOI: 10.36724/2072-8735-2025-19-6-43-51.
- [15] X. Yang, S. Lu, W. Zhao, and Z. Zhao, "Exploring the Characteristics of an Intra-Urban Bus Service Network: A Case Study of Shenzhen, China," *ISPRS International Journal of Geo-Information*. 2019. Vol. 8, No. 11, p. 486. DOI: 10.3390/ijgi8110486.
- [16] Y. Cao, D. Jiang, and S. Wang, "Optimization for Feeder Bus Route Model Design with Station Transfer," *Sustainability*. 2022. Vol. 14, No. 5, p. 2780. DOI: 10.3390/su14052780.
- [17] Y. Wei, N. Jiang, Z. Li, D. Zheng, M. Chen, and M. Zhang, "An Improved Ant Colony Algorithm for Urban Bus Network Optimization Based on Existing Bus Routes," *ISPRS International Journal of Geo-Information*. 2022. Vol. 11, No. 5, p. 317. DOI: 10.3390/ijgi11050317.
- [18] A. I. Petrov, D. A. Petrova, "Sustainability of Transport System of Large Russian City in the Period of COVID-19: Methods and Results of Assessment," *Sustainability*. 2020. Vol. 12, No. 18, p. 7644. DOI: 10.3390/su12187644.

Information about authors:

Alexey A. Fadyushin, Industrial University of Tyumen, Associate Professor of the Department "Road Transport Operation", PhD in Technical Sciences, Tyumen, Russia, ORCID 0000-0001-7276-4315.

Artur I. Petrov, Industrial University of Tyumen, Associate Professor of the Department "Road Transport Operation", PhD in Technical Sciences, Associate Professor, Tyumen, Russia, ORCID 0000-0003-2634-0567.

Evgeniya V. Lihajrova, Industrial University of Tyumen, graduate student of the Department "Road Transport Operation", Tyumen, Russia.

Vladimir D. Shepelev, South Ural State University (National Research University), Associate Professor of the Department of Automobile Transportation, PhD in Technical Sciences, Associate Professor, Chelyabinsk, Russia, ORCID 0000-0002-1143-2031.

NUMERICAL-ANALYTICAL AND SIMULATION MODELING OF A QUEUING SYSTEM WITH HYPER-ERLANG DISTRIBUTION OF THE INPUT FLOW

DOI: 10.36724/2072-8735-2026-20-5-49-56

Manuscript received 18 February 2026;

Accepted 24 April 2026

Veniamin N. Tarasov,
Povolzhskiy state university of telecommunications
and informatics, Samara, Russia,
veniamin_tarasov@mail.ru

Nadezhda N. Bakhareva,
Povolzhskiy state university of telecommunications
and informatics, Samara, Russia,
nadin1956_04@inbox.ru

Keywords: GPSS WORLD simulation system, queueing systems,
average waiting time in queue, average queue length, Lindley
equation, spectral method

This paper presents the results of a study of a queueing system (QS) described by a hyper-Erlangian input flow and exponential service time. The hyper-Erlangian distribution is known to be a special case of phase distributions, which have become a mathematical tool for analyzing telecom traffic in future-generation networks, characterized by high variability and exhibiting self-similarity. To construct a numerical analytical model of the average waiting time of requests in a queue, a spectral method was used to solve the Lindley integral equation, finding the zeros and poles of the spectral decomposition as a ratio of rational functions. To build a simulation model, the logical switch method in the GPSS World discrete-event simulation system was used. This paper presents numerical-analytical and simulation models for the average queue wait time for requests in a system with a second-order hyper-Erlang distribution for the input flow. Constructing the simulation model required developing a pseudo-random sequence generator for a second-order hyper-Erlang distribution, which is not available in the GPSS World function library. The adequacy of the developed generator's performance was confirmed by statistical tests. To assess the accuracy of the resulting solution, computational experiments were conducted for small, medium, and high values of the time interval variation coefficients and system load. The adequacy of the results is confirmed by a comparison of the simulation data using the presented numerical-analytical and simulation models and computational experiments in Mathcad.

Information about authors:

Veniamin N. Tarasov, Professor of the Department of Computer Science and Robotic Systems, Povolzhskiy state university of telecommunications and informatics, Samara, Russia. 0000-0002-9318-0797

Nadezhda N. Bakhareva, Professor of the Department of Computer Science and Robotic Systems, Povolzhskiy state university of telecommunications and informatics, Samara, Russia. 0000-0002-9850-7752

Для цитирования:

Тарасов В. Н., Бахарева Н. Ф. Численно-аналитическое и имитационное моделирование системы массового обслуживания с гиперэрланговским распределением входного потока // Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 49-56.

For citation:

V. N. Tarasov, N. F. Bakhareva, "Numerical-analytical and simulation modeling of a queueing system with hyper-Erlang distribution of the input flow," T-Comm, 2026, vol. 20, no. 5, pp. 49-56.

Introduction

A fundamental principle of general systems theory states that the average queue wait time is nonlinearly dependent on the coefficients of variation of arrival and service time intervals [1]. Consequently, the wider the range of variability of these coefficients of variation, ensured by the distribution law, the better suited the queuing system (QS) is for traffic modeling. These requirements are satisfied by the hyperexponential and hyper-Erlang distributions, which are special cases of phase distributions that are widely used to model highly variable traffic.

Modern telecommunications traffic varies greatly over time, making hyperexponential and hyper-Erlang distributions vital for its accurate modeling. In this article, in addition to constructing a numerical-analytical model of queuing using the hyper-Erlang distribution law, we also consider the need for such models in the GPSS WORLD system, proposing a new solution based on the logical switch mechanism. The universal discrete-event simulation system GPSS WORLD is used to model various production systems that can be represented as queuing systems. Its library contains numerous programs, including software random number generators based on the standard $U(0,1)$ uniform distribution.

Due to the difficulty of developing generators for probability mixture distribution laws, this system does not include generators for phase distributions, including hyper-Erlang and hyper-exponential distributions as probability mixture distributions. The cited literature and many other scientific publications confirm the lack of openly available results similar to those presented by the authors [2-7]. This fact complicates the modeling of general-purpose G/G/1 and G/G/m queueing systems, which best describe modern telecom traffic.

The results presented in this article are intended to partially address the aforementioned shortcomings of the GPSS WORLD modeling system.

It is known, for example [2], that the hyper-Erlang distribution can be constructed as a probability mixture of normalized Erlang distributions with weight coefficients p and $1-p$. For example, the second-order hyper-Erlangian density function has the form

$$f(t) = 4p\lambda_1^2 te^{-2\lambda_1 t} + 4(1-p)\lambda_2^2 te^{-2\lambda_2 t}, \quad (1)$$

and provides the coefficient of variation $c \in (1/\sqrt{2}, \infty)$.

From the definition of the two-parameter gamma distribution

$$\text{with density function } f(t) = \begin{cases} \frac{\lambda^\alpha t^{\alpha-1} e^{-\lambda t}}{\Gamma(\alpha)}, & t \geq 0; \\ 0, & t < 0, \end{cases} \text{ it follows}$$

that for a positive integer value of k ($\alpha=k$), the distribution with density function

$$f(t) = \lambda^k t^{k-1} e^{-\lambda t} \quad (2)$$

represents the Erlang distribution of order k . The numerical characteristics of distribution (2) depend on its order k , which creates certain problems when approximating flat distributions by the Erlang law. However, such problems do not arise when using the normalized Erlang distribution. The library generator of the gamma distribution GAMMA allows generating random sequences with the distribution (2), so we use (2) in the density function of the hyper-Erlang distribution as a probability mixture

$$f(t) = p\lambda_1^2 te^{-\lambda_1 t} + (1-p)\lambda_2^2 te^{-\lambda_2 t}. \quad (3)$$

In [2], it is noted that at high coefficients of variation, (1) and (3) can describe heavy-tailed distributions. Furthermore, [2] provides considerable detail about the hyper-Erlang distribution, establishing that the density function (1) can be viewed as an alternative representation of the second-order hyper-Erlang density function (3). This article is devoted to the construction of a simulation model of a QS with input distribution (3) in the GPSS WORLD system with a comparison with a numerical-analytical model. To this end, this paper presents a new method for generating second-order hyper-Erlang distributions in the GPSS WORLD modeling system, filling a gap in available tools for modeling variable telecommunication traffic.

As no such generator currently exists, this work provides a novel method, using a logical switches mechanism. In the future, this approach will allow us to demonstrate high-dimensional examples instead of simple examples. The wide range of coefficients of variation limits the possibilities of simulating data transmission systems for various purposes, because these distributions are underestimated. Similar work with hyperexponential input distribution is presented in [10]. It should be noted that the hyper-Erlang distribution has a wider range for the coefficient of variation than the hyper-exponential distribution.

The article also uses methods and techniques for approximating distribution laws using the initial moments of distributions [8-14]. Relatively new results in the field of simulation modeling are presented in [15-16].

1. Problem Statement

We consider a queuing system $HE_2/M/1$, which is described by the distribution density functions of arrival intervals HE_2 :

$$a(t) = p\lambda_1^2 te^{-\lambda_1 t} + (1-p)\lambda_2^2 te^{-\lambda_2 t} \quad (4)$$

and service time M :

$$b(t) = \mu e^{-\mu t}. \quad (5)$$

The article sets the task of constructing a QS simulation model with input distribution (3) in the GPSS WORLD system and comparing its results with a numerical-analytical model. To this end, this paper also aims to construct a method for generating a second-order hyper-Erlang distribution in the GPSS WORLD modeling system to fill the gap in available tools for modeling highly variable telecom traffic.

2. Theoretical solution for the $HE_2/M/1$ system

Theoretical analysis for the $HE_2/M/1$ system with distribution HE_2 of the form (1) was carried out in [8]. As noted above, distributions (1) and (3) differ in numerical characteristics. Therefore, the analytical model of the system under consideration shown below differs from the model considered in [8] and is also presented for the first time. The spectral decomposition method [1] was used to obtain a theoretical solution of the problem for the $HE_2/M/1$ system. Let us first write down the Laplace transforms for distributions (4) and (5):

$$A^*(s) = p \left(\frac{\lambda_1}{\lambda_1 + s} \right)^2 + (1-p) \left(\frac{\lambda_2}{\lambda_2 + s} \right)^2, \quad B^*(s) = \frac{\mu}{s + \mu}.$$

For the considered system, the spectral expansion takes the form

$$\frac{\alpha(s)}{\beta(s)} = \left[p \left(\frac{\lambda_1}{\lambda_1 - s} \right)^2 + (1-p) \left(\frac{\lambda_2}{\lambda_2 - s} \right)^2 \right] \cdot \left(\frac{\mu}{\mu + s} \right) - 1.$$

To continue the expansion and reduction of expressions, we introduce intermediate parameters

$$a_0 = \lambda_1^2 \lambda_2^2, \quad a_1 = 2\lambda_1 \lambda_2 [p\lambda_1 + (1-p)\lambda_2], \quad a_2 = p\lambda_1^2 + (1-p)\lambda_2^2.$$

The spectral expansion will take the form

$$\begin{aligned} \frac{\alpha(s)}{\beta(s)} &= \frac{\mu(a_0 - a_1s + a_2s^2) - (\lambda_1 - s)^2 (\lambda_2 - s)^2 (\mu + s)}{(\lambda_1 - s)^2 (\lambda_2 - s)^2 (\mu + s)} = \\ &= \frac{-s(s^4 + c_3s^3 + c_2s^2 + c_1s + c_0)}{(\lambda_1 - s)^2 (\lambda_2 - s)^2 (\mu + s)} = \frac{-s(s + s_1)(s - s_2)(s - s_3)(s - s_4)}{(\lambda_1 - s)^2 (\lambda_2 - s)^2 (\mu + s)}. \end{aligned}$$

Finally

$$\frac{\alpha(s)}{\beta(s)} = \frac{-s(s + s_1)(s - s_2)(s - s_3)(s - s_4)}{(\lambda_1 - s)^2 (\lambda_2 - s)^2 (\mu + s)}. \quad (6)$$

To find the zeros and poles of expansion (6), we select a polynomial of the fourth degree from the numerator

$$s^4 + c_3s^3 + c_2s^2 + c_1s + c_0 \quad (7)$$

with coefficients collected using symbolic operations Mathcad

$$\begin{aligned} c_0 &= a_1\mu + a_0 - 2\mu\lambda_1\lambda_2(\lambda_1 + \lambda_2), \\ c_1 &= \mu(\lambda_1^2 + 4\lambda_1\lambda_2 + \lambda_2^2 - a_2) - 2\lambda_1\lambda_2(\lambda_1 + \lambda_2), \\ c_2 &= \lambda_1^2 + \lambda_2^2 + 4\lambda_1\lambda_2 - 2\mu(\lambda_1 + \lambda_2), \quad c_3 = \mu - 2(\lambda_1 + \lambda_2). \end{aligned}$$

Polynomial (7) has one real negative root $-s_1$. The next three roots in this case represent one real positive and two complex conjugates with a positive real part. Next, we determine the components of the expansion based on the type of roots of the numerator of the expansion

$$\alpha(s) = s(s + s_1) / (\mu + s), \quad \beta(s) = -\frac{(2\lambda_1 - s)^2 (2\lambda_2 - s)^2}{(s - s_2)(s - s_3)(s - s_4)}.$$

Using the found components of the spectral decomposition, we determine the Laplace transform for the waiting time density function

$$W^*(s) = \frac{s_1(s + \mu)}{\mu(s + s_1)}, \quad \text{and through it, the average waiting time}$$

in the queue

$$\bar{W} = 1/s_1 - 1/\mu. \quad (8)$$

To determine the value of the root s_1 of the polynomial (7), it is necessary to express the values of the unknown parameters λ_1 , λ_2 , p of the distribution (4) and μ of the distribution (5) through its initial moments:

$$\bar{\tau}_\lambda = \frac{2p}{\lambda_1} + \frac{2(1-p)}{\lambda_2}, \quad \bar{\tau}_\lambda^2 = \frac{6p}{\lambda_1^2} + \frac{6(1-p)}{\lambda_2^2}, \quad (9)$$

$$\bar{\tau}_\mu = \frac{1}{\mu}, \quad \bar{\tau}_\mu^2 = \frac{2}{\mu^2}.$$

Equations (10), together with the squared coefficient of variation $c_\lambda^2 = \sigma_\lambda^2 / (\bar{\tau}_\lambda)^2 = [\bar{\tau}_\lambda^2 - (\bar{\tau}_\lambda)^2] / (\bar{\tau}_\lambda)^2$, make it possible to find all three distribution parameters (4). Let's write these values

$$\begin{aligned} \lambda_1 &= 4p / \bar{\tau}_\lambda, \quad \lambda_2 = 4(1-p) / \bar{\tau}_\lambda, \\ p &= 1/2 \pm \sqrt{1/4 - 3/[8(1+c_\lambda^2)]}. \end{aligned} \quad (10)$$

In this case, any of the two numbers can be taken as the value of the parameter p . From the condition of non-negativity of the expression under the square root, it follows that $c_\lambda \geq 1/\sqrt{2}$ [8-9].

A similar solution for the HE₂/M/1 system is presented in the author's paper [8]; for the case where the HE₂ distribution is formulated as a probability mixture of normalized Erlang (1) distributions. As established previously, the normalized distribution (1) and the usual distribution (3) have different initial moments. Consequently, many intermediate results (7) differ from those given in this article. Nonetheless, the primary result for the average waiting time remains the same.

Below in Figure 1 is an example of a calculation using the proposed QS model HE₂/M/1 for the case of a load factor $\rho = \bar{\tau}_\mu / \bar{\tau}_\lambda = 0.9$, a coefficient of variation $c_\lambda = 2$ and a unit service time $\bar{\tau}_\mu = 1$.

$$\begin{aligned} \tau_\lambda &:= \frac{10}{9} \quad c_\lambda := 2 \quad \tau_\mu := 1 \quad c_\mu := 1 \quad \mu := \frac{1}{\tau_\mu} = 1 \\ p &:= \frac{1}{2} + \sqrt{\frac{[2(1+c_\lambda^2)-3]}{8(1+c_\lambda^2)}} = 0.9183 \quad \lambda_1 := 4 \cdot \frac{p}{\tau_\lambda} = 3.306 \quad \lambda_2 := \frac{4(1-p)}{\tau_\lambda} = 0.294 \\ a_0 &:= \lambda_1^2 \lambda_2^2 \quad a_1 := 2 \cdot \lambda_1 \lambda_2 [p \lambda_1 + (1-p) \lambda_2] \quad a_2 := p \lambda_1^2 + (1-p) \lambda_2^2 \\ C_3 &:= \mu - 2(\lambda_1 + \lambda_2) = -6.2 \quad C_2 := -2 \cdot \mu (\lambda_1 + \lambda_2) + 4 \cdot \lambda_1 \lambda_2 + (\lambda_1^2 + \lambda_2^2) = 7.704 \\ C_1 &:= \mu (\lambda_1^2 + 4 \lambda_1 \lambda_2 + \lambda_2^2 - a_2) - 2 \lambda_1 \lambda_2 (\lambda_1 + \lambda_2) = -2.138 \\ C_0 &:= a_0 + a_1 \mu - 2 \mu \lambda_1 \lambda_2 (\lambda_1 + \lambda_2) = -0.105 \\ \text{Given} \\ S^4 + C_3 S^3 + C_2 S^2 + C_1 S + C_0 &= 0 \\ \text{Find}(S) \rightarrow (1.13E+000 \quad 4.64E+000 \quad -4.239E-002 \quad 4.722E-001) \\ S_1 &:= 0.042393653924057312415 \quad S_2 := 5.0877761192984934606 \\ S_3 &:= 0.033679284488540946276 \quad S_4 := 0.008129324989322733775 \\ W &:= \frac{1}{S_1} - \frac{1}{\mu} = 22.58844 \quad Nq := \frac{W}{\tau_\lambda} = 20.33 \end{aligned}$$

Fig. 1. Calculation example on Mathcad

Figure 1 presents an example of a numerical calculation of the model, which can be used to evaluate the numerical calculation algorithm.

In conclusion of the construction of the numerical-analytical model, we present Table 1, which compares the results for our system in the case of a relatively small variation coefficient $c_\lambda=2$ with the data of known systems for different values of the load ρ .

Table 1

A simple database for comparing systems

ρ	Average waiting time		
	HE ₂ /M/1	M/M/1	E ₂ /M/1
0,1	0,08	0,11	0,03
0,5	2,00	1,00	0,62
0,9	22,59	9,00	6,59

3. Construction of a simulation model for the system under consideration

An analytical representation of the hyper-Erlang distribution (4) suggests an initial approach to modeling using the GPSS World TEST operator. This is a conditional jump operator depending on whether a given condition is met. In such a model, transactions will be directed with probability p to the first phase of the hyper-Erlang law and with probability $1-p$ to the second phase, as shown in the model text below. The simulation model code is presented in Appendix 1. Here the line HYPER1 FVARIABLE means the command to call the generator of the second-order Erlang distribution as a special case of the Gamma distribution and assign the calculated value to the arithmetic variable HYPER1.

The results of the simulation with the initial data from the Matcad calculations (Fig. 1) are shown in Fig. 2. To maintain continuity between the numerical-analytical and simulation models, we use the same initial data for the system during simulation.

LABEL	LOC	BLOCK	TYPE	ENTRY	COUNT	CURRENT	COUNT	RETRY
	1	TEST		0	0	0	0	
	2	GENERATE		917939	0	0	0	
	3	TRANSFER		917939	0	0	0	
MET_1	4	GENERATE		82079	0	0	0	
MET_2	5	QUEUE		1000018	17	0	0	
	6	SEIZE		1000001	1	0	0	
	7	DEPART		1000000	0	0	0	
	8	ADVANCE		1000000	0	0	0	
	9	RELEASE		1000000	0	0	0	
	10	TERMINATE		1000000	0	0	0	

FACILITY	ENTRIES	UTIL.	AVE.TIME	AVAIL.	OWNER	PEND	INTER	RETRY	DELAY
CHAN	1000001	0.901	1.001	1	999992	0	0	0	17

QUEUE	MAX	CONT.	ENTRY	ENTRY(0)	AVE.CONT.	AVE.TIME	AVE.(0)	RETRY
QCHAN	69	18	1000018	128658	6.012	6.678	7.665	0

Fig. 2. Results of the initial simulation model run

The analysis of the model run results (Fig. 2) shows that approximately 918 thousand transactions are sent to the first phase, while 82 thousand transactions to the second phase. This distribution corresponds precisely to the specified probabilities of 0.918 and 0.082. As shown in Figure 2, the load factor is 0.9 and the average service time is one, which is completely consistent with the given initial data in Figure 1. At the same time, the main result, namely the average waiting time, equal to 6.678, does not coincide with the results of the analytical model (Fig. 1), which is 22.588 units of model time.

Thus, we came to the need to consider the differences between the analytical and simulation approaches. The issue arises from the structure of the simulation model. In its current implementation, incoming requests are not delayed in the Erlang phases of the hyper-Erlang distribution law for a given phase operation time. Consequently, the queueing delays produced by the simulation are characteristic of a simpler E₂/M/1 system, not the intended HE₂/M/1 system. We will consider this approach to constructing a simulation model as an instructive (unsuccessful) example.

To construct an adequate simulation model, it is necessary to clarify the main difference between the theoretical hyper-Erlang distribution (4) and the discrete-event functioning of the two-phase distribution. In a theoretical distribution, a request entering the system for servicing instantly goes through an "either or" scheme with probabilities p and $1-p$ – the first phase or the second. In discrete event modeling, before a requirement moves into a particular phase, that phase (state) must be defined and opened for a certain time using logical switches. Therefore, the simulation circuit must include logical switches with two states: on and off. Such a simulation circuit is shown in Figure 3.

In the discrete-event model, the two-phase functioning of the hyper-Erlang process (Fig. 3) occurs as follows. With probability p , the generated transaction is sent to the first phase of the hyper-Erlang process after it is determined and transferred to the on state and remains there for a time of $2/\lambda_1$, and with probability $1-p$, it is sent to the second phase and remains there for $2/\lambda_2$ units of model time. The circuit includes logical switches with two states: on, off.

The quantities $2/\lambda_1$ and $2/\lambda_2$ here represent the first initial moments of the second-order Erlang distribution for the first and second phases.




Fig. 3. Formation of a Two-Phase Hyper-Erlang Distribution. The phases are switched on alternately depending on the probability p and work for an arbitrary time with an average value indicated on the diagram

The two states are controlled by the LOGIC operator, where the A parameter serves as the key's identifier. The operating mode is specified by the letter X: the active state is set using the S (set) value, and deactivation is performed using the R (reset) value. Depending on the given probability variable p , the program code provides for the sequential activation of Switch1 and Switch2 objects, which act as logical keys.

The use of switches alone does not complete the model. It is necessary to ensure that transactions proceed through phases only when the switch is active. For this purpose, a GATE condition checker (in let-in mode) is used, which regulates the flow depending on the state of object A. Modeling requires specifying the duration of active switch operation. For example, the expression $T_{\#3.1}$ defines the operating time, where the average phase interval is adjusted by an empirical factor of 3.1. This factor is selected empirically to minimize deviations in the QS characteristics from actual data. The GPSS World program code is given in Appendix 2.

Next, we will establish the initial data for the simulation model, which must coincide with the data of the numerical-analytical model. To do this, we take a loading factor equal to 0.9, a variation coefficient for the input flow of 2.0, and distribution parameters (4) determined by expressions (10)

$$p = \frac{1}{2} - \sqrt{\frac{2(1+c_\lambda^2)-3}{8(1+c_\lambda^2)}} = 0,082, \quad 1-p = 0,918, \quad \lambda_1 = 0.295, \quad \lambda_2 = 3.304.$$

Let's establish a unit model service time. All these initial data can be found in the program code in Appendix 2. Figure 4 shows the simulation results.

Notations used in the simulation model.

P_1 is a probability p from the theoretical model, P_2 is a probability $1-p$. T_1 and T_2 here are half the values of the averages $2/\lambda_1$ and $2/\lambda_2$ for the first and second phases of the hyper-Erlang distribution.

Other notations are related to features of the GPSS WORLD modeling language, such as block labels and library function input parameters for generators.

FACILITY	ENTRIES	UTIL.	AVE.TIME	AVAIL.	OWNER	PEND	INTER	RETRY	DELAY
CHAN	1000001	0.898	1.000	1	2008099	0	0	0	1

QUEUE	MAX	CONT.	ENTRY	ENTRY(0)	AVE.CONT.	AVE.TIME	AVE.(0)	RETRY
QCHAN	175	2	1000002	52010	20.300	22.623	23.864	0

Fig. 4. The simulation results for QS HE₂/M/1 with a control constant of 3,1. Here the designations of the standard GPSS WORLD report are saved

The simulation results shown in Figure 4 confirm that the given input data and the simulation results match. The key performance indicators of the system, such as the average queue waiting time of 22.623-time units, is close to the numerical result of 22.59, and the average queue length of 20.30 is also almost the same as the numerical result of 20.33 in Figure 1. Thus, the experimental selection of the durations of active operation of switches T1 and T2 allows us to construct an adequate simulation model. Thus, the control constant in the simulation model is optimized, which ensures the best output characteristics of the system. In the future, this may help in constructing general simulation models for PH/PH/1 systems with phase distributions.

We now analyze the simulation model's behavior with the control constant set below and above 3.1. First, for values less than 3.1 (Figure. 5 – control constant is equal to 3.0), second, for values above than 3. 1 (Fig. 6 – control constant is equal to 3.2).

FACILITY	ENTRIES	UTIL.	AVE.TIME	AVAIL.	OWNER	PEND	INTER	RETRY	DELAY
CHAN	1000001	0.898	1.000	1	2006416	0	0	0	0

QUEUE	MAX	CONT.	ENTRY	ENTRY(0)	AVE.CONT.	AVE.TIME	AVE.(0)	RETRY
QCHAN	191	1	1000001	51574	19.749	21.990	23.186	0

Fig. 5. The simulation results for QS HE₂/M/1 with a control constant of 3,0

FACILITY	ENTRIES	UTIL.	AVE.TIME	AVAIL.	OWNER	PEND	INTER	RETRY	DELAY
CHAN	1000001	0.899	1.000	1	2005184	0	0	0	13

QUEUE	MAX	CONT.	ENTRY	ENTRY(0)	AVE.CONT.	AVE.TIME	AVE.(0)	RETRY
QCHAN	238	14	1000014	50137	20.944	23.307	24.537	0

Fig. 6. The simulation results for QS HE₂/M/1 with a control constant of 3,2

Thus, the model demonstrates the expected relationship where an increase in service parameters leads to a decrease in waiting time and queue length, and vice versa. A practical limitation of the proposed approach, however, is its dependence on knowing the exact or approximate values of the system's output characteristics in advance. Future research could focus on developing methods to bypass and eliminate this drawback.

4. Quality check of submitted pseudo-random number Generator and verification of the simulation model

The problem of checking the quality of the proposed pseudo-random variable generator for the hyper-Erlang distribution law is that this distribution law is completely absent from the libraries of known programs for processing statistical data for the purpose of selecting the corresponding distribution law. Consequently, exporting the results of the proposed generator to any known software products is impossible. Therefore, to test the quality of the generated sequences, we will have to re-solve the main problem of recognition and selection of the distribution law using the null hypothesis H_0 .

To do this, we must add to the program code given in Appendix 2 a set of command operators for generating random intervals of incoming requests and processing them in the form of tables and histograms. Let's list them: InterArr TABLE X\$Arr,1,1,20 (Building a table of receipt interval values for a statistical series and a histogram); INITIAL X\$Time,0 (Setting the initial value of "Time" to zero); Fun VARIABLE (AC1-X\$Time) (Determination of the function for the values of interarrivals); SAVEVALUE Arr,V\$Fun (Enter in the cell "Arr" the number determined by the function "Fun"); SAVEVALUE Time,AC1 (Enter in the cell "Time" the current value of the absolute model time); TABULATE InterArr (Tabulation of interval values between arrivals); MARK 2 (Enter in cell "2" the value of the current absolute model time). We restrict ourselves to a small number of tests 500. It should be noted that such number of tests will reflect the transient process of the system functioning. The START 500 statement will generate 505 transactions then (Fig. 7).

This could be avoided if there was a possibility to export the generation results into well-known statistical data processing programs.

It is known that varying the width of the histogram digit (Fig. 8) allows one to obtain various Pearson statistics. We combine discharges with low relative frequencies so that at least 5 values of a random variable fall into each interval, as shown in Table 2 [18-20].

QUEUE	MAX	CONT.	ENTRY	ENTRY(0)	AVE.CONT.	AVE.TIME	AVE.(0)	RETRY
QCHAN	50	5	505	15	17.614	18.612	19.181	0

TABLE	MEAN	STD.DEV.	RANGE	RETRY	FREQUENCY	CUM.%
INTERARR	1.172	2.159		0		
			- 1.000		391	77.43
			1.000 - 2.000		69	91.09
			2.000 - 3.000		10	93.07
			3.000 - 4.000		5	94.06
			4.000 - 5.000		4	94.85
			5.000 - 6.000		8	96.44
			6.000 - 7.000		6	97.62
			7.000 - 8.000		3	98.22
			8.000 - 9.000		2	98.61
			9.000 - 10.000		3	99.21
			10.000 - 11.000		1	99.41
			11.000 - 12.000		1	99.60
			12.000 - 13.000		1	99.80
			13.000 - 14.000		0	99.80
			14.000 - 15.000		0	99.80
			15.000 - 16.000		1	100.00

Fig. 7. Statistical distribution of arrival intervals for QS HE₂/M/1. Part of the standard GPSS World report is shown here. With a small number of tests, we have a case of a transient process




Fig. 8. HE2 distribution histogram. The histogram is built using standard GPSS WORLD tools: Window → Simulation Window → Table Window

Here I is a digits of the histogram, m_i is the number of hits in the i -th digit, p_i^* are the relative frequencies of hits, p_i are the probabilities of hits in the given digit

$$p_i = \int_{t_{i-1}}^{t_i} [p\lambda_1^2 te^{-\lambda_1 t} + (1-p)\lambda_2^2 te^{-\lambda_2 t}] dt. \text{ The value of the Pearson statistics is determined using the expression}$$

$$\chi^2 = \sum_{i=1}^K \frac{(m_i - p_i \cdot N)^2}{p_i \cdot N}.$$

Table 2

Corrected statistical series and calculation of statistics χ^2

I	i	p_i^*	p_i	$505 p_i$	χ^2
0-1	391	0,7743	0,7763	392,03	0,003
1-2	69	0,1366	0,1423	71,86	0,114
2-3	10	0,0198	0,0173	8,74	0,183
3-5	9	0,0178	0,0177	8,94	0,000
5-6	8	0,0158	0,0077	3,89	4,347
6-7	6	0,0119	0,0068	3,43	1,917
7-9	5	0,0099	0,0108	5,45	0,038
9-∞	7	0,0139	0,0211	10,66	1,254
	$\Sigma=505$	$\Sigma=1,0$	$\Sigma=1,0$	$\Sigma=505$	$\Sigma=7,86$

The obtained test value $\chi^2=7.86$ is compared with the table values with the number of degrees of freedom $r=4$ to determine the level of significance. A quantile (significance level) of 0.05 chi squared distribution with four degrees of freedom gives the value $\chi^2(0.05; 4)=9.49$. The calculated value $\chi^2=7.86$ is less than 9.49, therefore, the hypothesis of the hyper-Erlang distribution law for this sample is not rejected. Here, the null hypothesis H_0 is the fact that the values of this sample are subject to the hyper-Erlang distribution. The alternative hypothesis H_1 – the hyper-Erlang distribution law is rejected. Thus, the reliability of the simulation model is confirmed by comparison with the results of analytical modeling obtained by the spectral solution method presented in [8-10].

To increase the reliability of the results, we apply the Kolmogorov-Smirnov statistical criterion. For this purpose, the empirical distribution function $F_n(t)$ for the request inter-arrival intervals was constructed using the p_i^* from Table 2. The results of these calculations are presented in Table 3.

Table 3

Data for the Kolmogorov-Smirnov test

Points	$F_n(t)$	$F(t)$	$F_n(t) - F(t)$
0	0,0	0,0	0,0
1	0,7743	0,7763	-0,0020
2	0,9109	0,9186	-0,0077
3	0,9307	0,9359	-0,0052
5	0,9485	0,9536	-0,0151
6	0,9643	0,9613	0,0030
7	0,9762	0,9681	0,0081
9	0,9861	0,9789	0,0072
∞	1,0	1,0	0,0

As shown in Table 3, the test statistic is $d=\max |F_n(t) - F(t)|=0,015$

and the Kolmogorov function parameter is $\lambda=d\sqrt{n}=0,337$. Considering the values of the Kolmogorov function $P(0,3)=1,000$ and $P(0,4)=0,997$ after interpolation, we get the probability $P=0,998$. Thus, the hypothesis of the hyperexponential distribution law is supported.

5. Results and Discussion

The paper presents the developed algorithm and simulation model for modeling the functioning of a QS with a second-order composite distribution formed from Erlang distributions with weights. It was noted above that this distribution law provides a wide range of the coefficient of variation. When developing the simulation model, a complex mechanism of logical switching of the phases of the distribution law was used, as well as the selection of a control constant, which made it possible to build an adequate simulation model for the passage of transactions within the model. At the same time, the control constant allows you to reduce the time of the transient process during simulation. Checking the quality of the presented generator on small samples shows their satisfactory functioning (Table 2).

6. Prospects for further research

Despite the relatively high accuracy of the constructed numerical-analytical and simulation models of queuing for a system with a hyper-Erlang distribution of the input flow, the authors see the need for further development of this direction for systems with phase distributions.

The presented models are limited by the possibility of using only two phases of the incoming process and two moments of distribution of the input flow, and this may be insufficient for modeling modern telecom traffic.

The transition to phase distributions is associated with the complexity of constructing a simulation model with the specifics of using logical switches for the phase structure of receipt and service processes.

Conclusion

This work addresses a gap in theory, as no prior studies on this topic were found in either Russian or English sources, nor are hyper-Erlang distribution generators available in the GPSS World library. The results presented by the authors make it possible to study queueing systems based on complex distribution laws. The approach involves comparing simulation results with theoretical results obtained by applying the spectral decomposition method to the Lindley integral equation.

In the article, Section 3, including all subsections and Section 4, contain new results that are not available in the Russian-language or English-language segments of scientific literature. This concerns numerical-analytical modeling and simulation modeling of systems with hyper-Erlang input distribution. Therefore, these sections present new results in computer modeling. The presented hyper-Erlang distribution generator based on logical switches of Erlang distribution phases operation has no analogues.

The authors confirm that the data supporting the findings of this study are available within the article [8-10] its supplementary materials.

Appendix 1

```
10 HYPER1 FVARIABLE (GAMMA(1,0,0.605,2))
20 HYPER2 FVARIABLE (GAMMA(1,0,6.78,2))
30 TEST L (RN1),0.918,MET_1
40 GENERATE V$HYPER1
50 TRANSFER ,MET_2
60 MET_1 GENERATE V$HYPER2
70 MET_2 QUEUE QCHAN
80 SEIZE CHAN
90 DEPART QCHAN
100 ADVANCE (Exponential (1,0,1.0))
110 RELEASE CHAN
120 TERMINATE 1
130 START 1000000
```

```
10 P_1 EQU 0.082
20 P_2 EQU (1-P_1)
30 T_1 EQU 3.39
40 T_2 EQU 0.302
50 GENERATE ,,1
60 Switch TRANSFER P_1,Met_2,Met_1
70 Met_1 TRANSFER ,Sw_1
80 Met_2 TRANSFER ,Sw_2
90 Sw_1 LOGIC S Switch1
100 ADVANCE (T_1#3.1)
110 LOGIC R Switch1
120 TRANSFER ,Switch
130 Sw_2 LOGIC S Switch2
140 ADVANCE (T_2#3.1)
150 LOGIC R Switch2
160 TRANSFER ,Switch
170 GENERATE (GAMMA(11,0,T_1,2))
180 GATE LS Switch1,Met_10
190 TRANSFER ,Met_20
200 GENERATE (GAMMA(21,0,T_2,2))
210 GATE LS Switch2,Met_10
220 Met_20 QUEUE QCHAN
230 SEIZE CHAN
240 DEPART QCHAN
250 ADVANCE (Exponential(31,0,1.0))
260 RELEASE CHAN
270 TERMINATE 1
280 Met_10 TERMINATE
290 START 1000000
```

Appendix 2

References

- [1] L. Kleinrock. Queueing Systems, Vol. I: Theory. New York: Wiley, 1975. 432 p.
- [2] T. I. Aliev. Osnovy modelirovaniya diskretnykh sistem, St. Petersburg: SPbSU ITMO, 2009. <https://books.ifmo.ru/file/pdf/466.pdf>.
- [3] V. N. Tarasov, N. F. Bahareva, "Ocenka kachestva predlozhennykh programmykh generatorov v sisteme GPSS WORLD na osnove sostavnykh raspredelenij," *T-Comm*, 2023, vol. 17, no. 11, pp. 35-40. DOI: 10.36724/2072-8735-2023-17-11-35-40
- [4] R. F. Malikov, Praktikum po diskretno-sobytiynomu modelirovaniyu slozhnykh sistem v srede ALINA GPSS (GPSS Studio), Moscow, Vologda: Infra-Inzheneriya, 2025. 368 p.
- [5] M. V. Shyman, M. V. Savchenko, "Generalized Queueing Model for telecommunication systems with diverse traffic," April 2026. DOI:10.32782/2663-5941/2026.1.1/2
- [6] Ya. Melnyk, I. Kulynych, Vy. Zahorodnykh, "General Characteristics of the GPSS simulation system," *Intellect XXI*, January 2024. DOI:10.32782/2415-8801/2024-2.12
- [7] A. Hristov, "Using Python for development of an application for building and experimenting with GPSS simulation models," November 2023, *31st National Conference with International Participation (TELECOM)*. DOI:10.1109/TELECOM59629.2023.10409696
- [8] V. N. Tarasov, "The analysis of two queueing systems HE2/M/1 with ordinary and shifted input distributions," *Radio Electronics, Computer Science, Control*, doi10.15588/1607-3274-2019-2-8
- [9] V. N. Tarasov and N. F. Bakhareva, "Comparative analysis of two queueing systems M/HE2/1 with ordinary and with the shifted input distributions," *Radio Electronics Computer Science Control*, doi10.15588/1607-3274-2019-4-5.
- [10] V. N. Tarasov and N. F. Bakhareva, "An approach to constructing a distribution generator in the form of a probabilistic mixture and its use for simulation of queueing system," *Journal of Simulation*, doi10.1080/17477778.2025.2513905 Indexed 2025-06-15.
- [11] O. Boxma, B. Zwart "Refined Asymptotics for Lindley's Integral Equation with Phase-Type Inputs," *Journal of Applied Probability*, 2024, vol. 61, no. 2, pp. 412-435. DOI: 10.1017/jpr.2023.94
- [12] A. J. Janssen "A Numerical Approach to Lindley's Equation via Rational Approximation," *Annals of Operations Research*, 2023, vol. 325, no. 1, pp. 589-614.
- [13] J. Abate, W. Whitt "Solving Lindley's Integral Equation via the Transform Inversion Method: The PH/PH/1 Case," *Operations Research Letters*, 2023, vol. 51, no. 4, pp. 367-373.
- [14] L. Wang, J. Smith "Generalized Lindley's Equation in Non-Stationary Queues with PH-distributions," *European Journal of Operational Research*, 2026, vol. 338 (In Press). DOI: 10.1016/j.ejor.2025.08.012
- [15] P. Buchholz, J. Kriege "Effective Approximation of Heavy-Tailed Distributions by Phase-Type Distributions," *Performance Evaluation*, 2023, vol. 162, Art. 102357, pp. 1-22.
- [16] Z. Yuan, M. Chen "Optimization of PH-distribution fitting via EM-algorithm for 6G Traffic Modeling," *Journal of Network and Computer Applications*, 2025, vol. 234, pp. 104-118. (Early Access, Jan 2025).

ЧИСЛЕННО-АНАЛИТИЧЕСКОЕ И ИМИТАЦИОННОЕ МОДЕЛИРОВАНИЕ СИСТЕМЫ МАССОВОГО ОБСЛУЖИВАНИЯ С ГИПЕРЭРЛАНГОВСКИМ РАСПРЕДЕЛЕНИЕМ ВХОДНОГО ПОТОКА

Тарасов Вениамин Николаевич, Поволжский государственный университет телекоммуникаций и информатики,
г. Самара, Россия, veniamin_tarasov@mail.ru

Бахарева Надежда Федоровна, Поволжский государственный университет телекоммуникаций и информатики,
г. Самара, Россия, nadin1956_04@inbox.ru

Аннотация

В работе представлены полученные результаты исследования системы массового обслуживания (СМО), описываемой гиперэрланговским входным потоком и экспоненциальным временем обслуживания. Известно, что гиперэрланговское распределение является частным случаем фазовых распределений, которые стали математическим аппаратом для анализа телетрафика сетей будущего поколения, характеризующегося высокой вариативностью и обладающего эффектом самоподобия. Для построения численно-аналитической модели среднего времени ожидания требований в очереди использован спектральный метод для решения интегрального уравнения Линдли с нахождением нулей и полюсов спектрального разложения в виде отношения рациональных функций. Для построения имитационной модели использован метод логических переключателей в дискретно-событийной системе моделирования GPSS World. В работе представлены численно-аналитическая и имитационная модели для среднего времени ожидания требований в очереди для системы с гиперэрланговским распределением второго порядка для входного потока. Для построения имитационной модели потребовалась разработка генератора псевдослучайных последовательностей для гиперэрланговского распределения второго порядка, которого нет в библиотеке функций GPSS World. Адекватность функционирования разработанного генератора подтверждена статистическими тестами. Для оценки точности полученного решения проведены вычислительные эксперименты для малых, средних и высоких значений коэффициентов вариаций временных интервалов и загрузки системы. Адекватность результатов подтверждается сопоставлением данных моделирования с помощью представленных численно-аналитической и имитационной моделей и вычислительными экспериментами в Mathcad.

Ключевые слова: Система моделирования GPSS WORLD, системы массового обслуживания, среднее время ожидания в очереди, средняя длина очереди, уравнение Линдли, спектральный метод.

Литература

1. Kleinrock L. Queueing Systems, Vol. I: Theory. New York: Wiley, 1975. 432 p.
2. Aliev T.I. Основы моделирования дискретных систем. СПб: СПбГУ ИТМО, 2009. <https://books.ifmo.ru/file/pdf/466.pdf>.
3. Тарасов В.Н., Бахарева Н.Ф. Оценка качества предложенных программных генераторов в системе GPSS WORLD на основе составных распределений // Т-Сотт: Телекоммуникации и Транспорт. 2023. Т. 17. № 11. С. 35-40. DOI: 10.36724/2072-8735-2023-17-11-35-40
4. Маликов Р.Ф. Практикум по дискретно-событийному моделированию сложных систем в среде ALINA GPSS (GPSS Studio): уч. пособие. Москва, Вологда: Инфра-Инженерия, 2025. 368 с.
5. Shyman M.V., Savchenko M.V. Generalized Queuing Model for telecommunication systems with diverse traffic. April 2026. DOI:10.32782/2663-5941/2026.1.1/2
6. Melnyk Ya., et. al. General Characteristics of the GPSS simulation system // Intellect XXI, January 2024. DOI:10.32782/2415-8801/2024-2.12
7. Hristov A. Using Python for development of an application for building and experimenting with GPSS simulation models // 31st National Conference with International Participation (TELECOM), November 2023 DOI:10.1109/TELECOM59629.2023.10409696
8. Tarasov V.N. The analysis of two queueing systems HE2/M/1 with ordinary and shifted input distributions // Radio Electronics, Computer Science, Control, doi10.15588/1607-3274-2019-2-8
9. Tarasov V.N. and Bakhareva N.F. Comparative analysis of two queueing systems M/HE2/1 with ordinary and with the shifted input distributions, "Radio Electronics Computer Science Control, doi10.15588/1607-3274-2019-4-5.
10. Tarasov V.N. and Bakhareva N.F. An approach to constructing a distribution generator in the form of a probabilistic mixture and its use for simulation of queueing system // Journal of Simulation, doi10.1080/17477778.2025.2513905 Indexed 2025-06-15.
11. Boxma O., Zwart B. Refined Asymptotics for Lindley's Integral Equation with Phase-Type Inputs // Journal of Applied Probability. 2024. Vol. 61, no. 2, pp. 412-435. DOI: 10.1017/jpr.2023.94.
12. Janssen A.J. A Numerical Approach to Lindley's Equation via Rational Approximation // Annals of Operations Research. 2023. Vol. 325, no. 1, pp. 589-614.
13. Abate J., Whitt W. Solving Lindley's Integral Equation via the Transform Inversion Method: The PH/PH/1 Case // Operations Research Letters. 2023. Vol. 51, No. 4, pp. 367-373.
14. Wang L., Smith J. Generalized Lindley's Equation in Non-Stationary Queues with PH-distributions // European Journal of Operational Research. 2026. Vol. 338 (In Press). DOI: 10.1016/j.ejor.2025.08.012.
15. Buchholz P., Kriege J. Effective Approximation of Heavy-Tailed Distributions by Phase-Type Distributions // Performance Evaluation. 2023. Vol. 162, Art. 102357, pp. 1-22.
16. Yuan Z., Chen M. Optimization of PH-distribution fitting via EM-algorithm for 6G Traffic Modeling // Journal of Network and Computer Applications. 2025. Vol. 234, pp. 104-118. (Early Access, Jan 2025).

Информация об авторах:

Тарасов Вениамин Николаевич, Заслуженный работник высшей школы РФ, доктор технических наук, профессор кафедры информатики и робототехнических систем, Поволжский государственный университет телекоммуникаций и информатики, Самара, Россия. ORCID: 0000-0002-9318-0797

Бахарева Надежда Федоровна, Доктор технических наук, профессор кафедры информатики и робототехнических систем, Поволжский государственный университет телекоммуникаций и информатики, Самара, Россия. ORCID: 0000-0002-9850-7752

ADAPTIVE TRAFFIC SIGNAL CONTROL BASED ON REINFORCEMENT LEARNING WITH CONSIDERATION OF VEHICLE AND PEDESTRIAN FLOWS

DOI: 10.36724/2072-8735-2026-20-5-57-66

Ksenia A. Polyantseva,
Moscow Technical University of Communications and Informatics,
Moscow, Russia, k.a.polyantseva@mtuci.ru

Mikhail G. Gorodnichev,
Moscow Technical University of Communications and Informatics,
Moscow, Russia, m.g.gorodnichev@mtuci.ru

Vladimir P. Kulagin,
Moscow Technical University of Communications and Informatics,
Moscow, Russia, v.p.kulagin@mtuci.ru

Manuscript received 02 March 2026;
Accepted 05 May 2026

Keywords: adaptive traffic light control, reinforcement learning, Deep Q-Network, traffic flows, pedestrian flows, SUMO, intelligent transportation systems

This paper addresses the problem of adaptive traffic signal control with joint consideration of vehicle and pedestrian flows. A Deep Q-Network-based method is proposed, in which the agent decides whether to keep the current traffic signal phase or switch to the next one based on the current state of the intersection. This state includes traffic lane congestion, the number of pedestrians in the crossing zone, and the current control phase. The main contribution of the paper is the development of a multi-component adaptive reward function. It includes vehicle delays, pedestrian waiting times, intersection capacity, and a penalty for excessive phase switching. When pedestrians accumulate in the crossing area, the pedestrian-related component of the reward is increased. The experimental evaluation was carried out in the SUMO microscopic traffic simulation environment. The proposed method was compared with fixed traffic light control. The results showed a reduction in average pedestrian and vehicle wait times, shorter queue lengths, and an increase in intersection capacity. These results confirm that reinforcement learning combined with an adaptive reward function can be used for more flexible and balanced urban intersection management.

Information about authors:

Ksenia A. Polyantseva, Associate Professor of the Department of Data Mining, Candidate of Technical Sciences, Moscow Technical University of Communications and Informatics, Moscow, Russia. ORCID: 0000-0002-7102-4208

Mikhail G. Gorodnichev, Head of the Department of Mathematical Cybernetics and Information Technology, Candidate of Technical Sciences, Moscow Technical University of Communications and Informatics, Moscow, Russia. ORCID: 0000-0003-1739-9831

Vladimir P. Kulagin, Professor of the Department of Mathematical Cybernetics and Information Technology, Doctor of Technical Sciences, Moscow Technical University of Communications and Informatics, Moscow, Russia. ORCID: 0000-0001-8826-6724

Для цитирования:

Полянцева К.А., Городничев М.Г., Кулагин В.П. Адаптивное управление светофорами на основе обучения с подкреплением с учетом потоков транспортных средств и пешеходов // Т-Сотм: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 57-66.

For citation:

K.A. Polyantseva, M.G. Gorodnichev, V.P. Kulagin, "Adaptive traffic signal control based on reinforcement learning with consideration of vehicle and pedestrian flows," T-Comm, 2026, vol. 20, no. 5, pp. 57-66.

Introduction

With increasing motorization and growing pressure on urban transport infrastructure, improving traffic management efficiency has become an important research and practical problem.

Traditional traffic signal control systems, based on fixed phase switching cycles, do not take into account the current traffic situation, leading to increased waiting times for vehicles and pedestrians, longer queues, and reduced intersection capacity.

Modern intelligent transport systems actively utilize machine learning and computer vision methods to analyze traffic situations in real time [1]. Of particular interest is the use of reinforcement learning, in which a control agent forms a control strategy based on interactions with the environment. Unlike predefined algorithms, this approach allows for adaptive traffic flow, accounting for queue accumulation, and minimizing over-all time losses [2].

Despite a significant amount of research in the field of adaptive intersection control, most existing work focuses primarily on optimizing traffic flows without explicitly considering pedestrian traffic. This limits the applicability of such solutions in urban environments, where the interests of all road users must be taken into account.

This raises the challenge of developing management methods that would jointly optimize traffic and pedestrian flows within a single model. This approach not only increases intersection capacity but also ensures more balanced management of various road users.

The aim of this paper is to develop and evaluate a method for adaptive traffic light control based on reinforcement learning, taking into account vehicle and pedestrian flows. To achieve this goal, the following tasks are addressed:

- developing a state model of a signalized intersection;
- developing a reward function that takes into account the delays of various traffic participants;
- constructing an algorithm for selecting control actions;
- experimentally evaluating the effectiveness of the proposed approach.

The main contribution of this paper lies not in the application of DQN to the traffic light control problem itself, but in the construction of a learning scheme with a multi-component adaptive reward function. Unlike vehicle-centric approaches, the proposed function explicitly accounts for pedestrian delays, dynamically enhances the pedestrian component as people accumulate in the crossing zone, and additionally penalizes excessive phase switching. This allows the agent to learn not only to increase throughput but also to maintain a balance between vehicle and pedestrian flows.

The practical significance of this paper lies in the potential application of the proposed approach to the development of intelligent traffic management systems within the framework of smart city concepts [3].

1. Related work

The development of traffic signal control methods has evolved from rigid fixed cycles to adaptive systems that use data on the current state of the transport network [4]. Classic approaches rely on predetermined phase plans and work well only under conditions of relatively stable demand. When traffic vol-

ume fluctuates unevenly, such schemes quickly lose effectiveness: green time may be allocated to a lightly loaded route, while queues form on other routes. This is why intelligent transport systems are increasingly focusing on methods that can adjust control based on the observed traffic situation.

Adaptive control systems, such as SCATS and SCOOT, have become important steps in this direction. They use data from road sensors and allow traffic signal control parameters to be modified based on the current traffic load. These solutions have demonstrated that the transition from fixed cycles to adaptive control does indeed reduce delays and improve throughput. However, such systems are typically based on heuristic rules, statistical models, or local optimization. They require manual tuning and are not always well-suited to new traffic scenarios. There's a lack of flexibility.

Reinforcement learning methods have seen significant development in recent years. In this approach, a traffic light is considered an agent that observes the state of the intersection, chooses an action, and receives a reward for its performance [5]. This approach eliminates the need to manually specify a switching policy, instead deriving it through interaction with the environment. Value-based methods, particularly DQN and its modifications, were most frequently used in early studies. They are suitable for problems with a discrete set of actions, such as choosing between maintaining the current phase and switching to the next. However, the performance of such methods depends heavily on how the state and reward function are defined. If the state reflects one aspect of the traffic flow, while the reward optimizes another, learning becomes less robust.

Modern research is gradually moving away from simple single-node approaches. For single intersections, Double DQN, Dueling DQN, PPO, and other deep reinforcement learning approaches are increasingly being used to improve training stability and accelerate convergence. For example, several studies have shown that improving the agent architecture, using a prioritized experience buffer, or switching to actor-critic methods can reduce average waiting times and queue lengths compared to fixed-time control and classical adaptive heuristics. However, such solutions are primarily focused on vehicle traffic flow. Pedestrians are either not considered or are only indirectly included.

A separate line of research concerns intersection network management. Here, the problem becomes more complex: the decision of one traffic light affects neighboring nodes, and a locally optimal action can worsen the condition of the entire traffic corridor. To address this problem, multi-agent reinforcement learning, graph neural networks, and inter-agent communication mechanisms are being used. In such approaches, each intersection can be treated as a separate agent, and information exchange between agents allows for the propagation of queues and the interaction of phases to be taken into account. Graph models additionally provide the ability to describe the network topology and the differences between intersections. This is an important step forward, especially for urban networks. However, the price of such flexibility is high: architectures become more complex, the need for communication between nodes increases, and transferring the model to another network requires additional testing.

Another area of research concerns the portability and generalizability of models. Federated learning, transfer learning, and methods that allow for training control systems for more than just one specific intersection configuration are increasingly dis-

cussed in the literature. This stems from a practical problem: a model that performs well in simulation for one network may perform poorly when the geometry, traffic volume, or phase set changes. Federated and graph approaches partially address this problem by allowing knowledge exchange between nodes or regions without transferring raw data. However, most of these solutions are still primarily tested in simulators. Real-world implementation remains rare.

Research that considers not only cars but also pedestrians is particularly important for this work. In an urban environment, traffic signal control cannot be viewed solely as a task of minimizing traffic delays. If only vehicle flow is optimized, the system may generate a strategy that is convenient for cars but uncomfortable or unsafe for pedestrians. Some studies propose pedestrian-aware approaches, where the objective function includes the total user delay or the safety indicators of pedestrian-vehicle conflicts. These studies demonstrate that explicitly considering the pedestrian component changes the nature of control and allows for more balanced decisions. However, such studies are significantly fewer in number than vehicle-centric approaches. This is a significant gap in the field.

Integrating computer vision also remains an important, but not entirely resolved, problem. Most reinforcement learning algorithms in traffic signal control use data obtained from a simulator or from idealized sensors: queue lengths, speeds, lane occupancy, and the number of vehicles. In a real urban environment, such data is often obtained from cameras, requiring a link between the perception and decision-making modules. There are studies where control is based on visual data or end-to-end processing of video streams. However, this area is still less mature than research based on features directly extracted from SUMO or detector data. Computer vision is especially rarely combined with explicit consideration of pedestrian flows in the reward function.

A general comparison of the approaches considered is provided in Table 1. While the table does not claim to be a comprehensive coverage of the literature on the topic, it highlights the key point: while most modern approaches have developed the algorithmic component of control well, the pedestrian component and visual perception data are still used infrequently.

Table 1

Comparison of approaches to adaptive control of traffic lights

Source	Method	Scale	Pedestrian consideration	Main limitation
[6]	Double DQN	1 intersection	No	Focus on transport metrics
[7]	PN-D3QN	1 intersection	No	No network coordination
[8]	PPO	1 intersection	No	Pedestrian flows are not included in the model
[9, 10]	MARL, agent communication	Network of intersections	No	Increasing complexity of architecture and data exchange
[11-13]	Graph MARL	Network of intersections	No	High complexity of the graph model
[14, 15]	Federated RL	Several networks	No	Testing primarily in simulation

[16]	Pedestrian-aware DRL	1 intersection	Yes	Limited number of scenarios and topologies
[17]	Safety-oriented DRL	1 intersection	Yes	A developed infrastructure of connected vehicles is required
[18, 19]	Vision-based control	1 intersection	Partially	The complexity of the transition from simulation to a real environment
The proposed approach	DQN with multi-component reward function	1 intersection	Yes	Requires further expansion to the intersection network

The comparison shows that reinforcement learning has already become one of the main tools for adaptive traffic signal control [20]. The most advanced approaches are related to multi-agent coordination, graph models, policy portability, and multi-objective optimization [21].

However, an important limitation remains: most work still focuses on vehicular metrics [22]. Pedestrian flows are considered less frequently, and the integration of computer vision data into the decision-making loop is usually considered separately from the problem of balancing vehicle and pedestrian delays.

The proposed method uses reinforcement learning to control a traffic signal, but the reward function is formed based on more than just vehicle metrics. It includes pedestrian delays, throughput, and penalties for excessive phase changes. This approach allows intersection control to be viewed as a problem of balancing multiple types of traffic participants, rather than as optimizing a single vehicle flow.

2. Problem statement

We consider a signalized intersection where vehicle and pedestrian traffic fluctuate over time. Traffic signal control is performed discretely: at each simulation step, the system receives information about the current state of the intersection and makes a decision to maintain or change the current phase. This setup aligns well with reinforcement learning problems, where the control agent sequentially interacts with the environment and adjusts its strategy based on the results of previous actions.

The problem is formalized as a Markov decision process:

$$\langle S, A, P, R \rangle,$$

where S is the set of environment states, A is the set of admissible actions, P is the state transition function, and R is the reward function. In this paper, the transition function is not defined analytically: it is determined by the dynamics of the transport environment in SUMO. The agent observes only the current state, applies an action, and receives a new state along with the reward value.

The state of the environment at time t is defined by the vector

$$S_t = \{n_1, n_2, \dots, n_{12}, p, \phi\},$$

where n_i is the number of vehicles in the i -th traffic lane, p is the number of pedestrians in the crossing zone, and ϕ is the

current traffic light phase. Thus, the agent obtains a compact description of the intersection: lane occupancy, pedestrian activity, and the current traffic light mode. The state vector has 14 dimensions.

Before feeding the values of n_i and p into the neural network model, they are normalized. This is necessary not only to speed up training. With different scales of input features, the network may overestimate some state components and largely ignore others. Normalization reduces this effect and makes learning more robust.

The agent's action set is defined as

$$A = \{a_0, a_1\},$$

where a_0 means maintaining the current phase, and a_1 switching to the next phase. This discrete set of actions was chosen deliberately. It simplifies control and makes the problem suitable for DQN, while still preserving the core control logic: the agent decides whether the current phase is sufficient to remain active or whether the traffic situation already requires switching.

In a real system, a traffic light cannot change phases arbitrarily frequently. This would create unstable control and could worsen traffic safety. Therefore, a minimum phase duration constraint is introduced. If a phase is active for less than the specified time, the switching action is blocked or considered undesirable. Additionally, a penalty for excessive switching is included in the reward function.

The reward function must reflect several goals simultaneously [23]. It is necessary to reduce vehicle waiting times, prevent excessive pedestrian waiting times, maintain intersection capacity, and avoid excessively frequent phase changes. The following reward form is used in this work:

$$R_t = -\alpha W_c - \beta W_p + \eta Q + \delta P_{prio} - \lambda S_{switch},$$

where W_c is the total waiting time of vehicles, W_p is the total waiting time of pedestrians, Q is the number of objects that passed the intersection per simulation step, P_{prio} is the pedestrian flow priority coefficient, and S_{switch} is the phase switching penalty. The coefficients α , β , η , δ and λ determine the relative importance of individual components.

Pedestrian priority is introduced not as a constant bonus, but as a response to the accumulation of pedestrian flow:

$$P_{prio} = \begin{cases} 1, & p < p_{th}, \\ k, & p \geq p_{th}, \end{cases}$$

where p_{th} is the pedestrian threshold, and $k > 1$ is the priority gain coefficient. This scheme avoids giving excessive priority to the pedestrian phase when the number of people is small, but increases its influence when the wait at the crossing becomes noticeable. It's a simple mechanism, but it makes the control less car-centric.

Additionally, the β coefficient, which is responsible for the penalty for waiting for pedestrians, can be adjusted. If the number of pedestrians exceeds the threshold, the weight of the pedestrian delay increases:

$$\beta_t = \begin{cases} \beta, & p < p_{th}, \\ \beta \cdot k_\beta, & p \geq p_{th}, \end{cases}$$

where $k_\beta > 1$ is the gain. In this case, the reward function becomes adaptive: it changes the balance of objectives depending on the current situation at the intersection.

The agent's goal is to find a strategy π that maximizes the expected discounted reward sum:

$$\max_{\pi} \mathbb{E} \left[\sum_{t=0}^{\infty} \gamma^t R_t \right],$$

where γ is the discount factor. The optimal strategy should not minimize a single metric, but rather balance between vehicle delays, pedestrian waiting times, throughput, and phase switching stability.

The Deep Q-Network algorithm is used to solve the problem. It approximates the action value function

$$Q(s, a; \theta),$$

where θ are the neural network parameters. The choice of DQN is due to the fact that the action space in the considered setting is discrete, and the state has a fixed dimension. This allows for the use of a relatively simple agent architecture and its training directly through interaction with the simulated environment.

3. Proposed method

This paper proposes a method for adaptive traffic light control based on the Deep Q-Network algorithm. Its core idea is to replace the predefined phase switching logic with a strategy that evolves as the agent interacts with the traffic environment. The agent receives the current intersection state, evaluates possible actions, and selects one. The environment then transitions to a new state, and the agent receives the value of the reward function. This gradually forms a control policy.

The overall design of the method includes several interconnected components: a simulation environment, a data collection module, a state generation module, a DQN agent, a control action application mechanism, and a reward calculation unit. SUMO is used as the traffic environment, and data exchange between the simulator and the control algorithm is accomplished via the TraCI interface [24]. This separation is convenient: SUMO is responsible for traffic dynamics, while the Python control module implements the learning algorithm and action selection.

At each simulation step, the system reads data on the number of vehicles in the traffic lanes and the number of pedestrians in the crossing zone. These values are combined with the current traffic light phase to form a state vector, S_t . The vector is then fed to a neural network model, which returns estimates, $Q(s_t, a)$, for the permissible actions. If the agent selects the phase-maintaining action, the traffic light continues to operate in its current mode. If the phase-switching action is selected, a phase-change command is sent via TraCI. A minimum phase duration constraint is also checked to prevent excessively frequent phase-switching.

The DQN agent architecture is compact. The input layer has a dimension of 14, corresponding to the number of features in the

state vector. Next, two fully connected hidden layers with 64 neurons each and a ReLU activation function are used. The output layer contains two neurons, each corresponding to one agent action: a_0 maintain the current phase, a_1 switch the phase.

Action selection in operational mode is performed according to the rule

$$a_t = \arg \max_{a \in A} Q(s_t, a; \theta),$$

where θ are the parameters of the underlying neural network.

During training, a ε -greedy strategy is used. With probability ε , the agent chooses a random action, and with probability $1-\varepsilon$, the action with the maximum value of the Q -function. At the beginning of training, a large ε value allows the agent to explore different behavioral options. Then, it gradually decreases, and the agent increasingly uses its accumulated experience. This is a simple mechanism, but without it, the model quickly gets stuck in a random local strategy.

To improve the stability of training, an experience replay buffer is used. Transitions of the form

$$(s_t, a_t, R_t, s_{t+1}, d_t),$$

where d_t is the end-of-episode indicator. Training is performed not on consecutive observations, but on random mini-samples from the buffer. This reduces the correlation between adjacent states, and the neural network receives more diverse examples. This is important for a transport environment: states in it often change smoothly, and training only on adjacent steps makes the model less stable.

In addition to the main network, a target network with parameters θ^- is used. It is updated less frequently than the main model and is used to calculate target values. For a transition from the buffer, the target value is specified as

$$y_t = \begin{cases} R_t, & d_t = 1, \\ R_t + \gamma \max_{a'} Q(s_{t+1}, a'; \theta^-), & d_t = 0. \end{cases}$$

The main network parameters are then updated by minimizing the error between the current estimate $Q(s_t, a_t; \theta)$ and the target value y_t . The Huber loss is used as the loss function, as it is less sensitive to outliers than the mean squared error.

The DQN agent training process can be described by the following sequence of steps:

1. The SUMO environment and the TraCI interface are initialized.
2. The main network $Q(s, a; \theta)$ and the target network $Q(s, a; \theta^-)$ are initialized.
3. A replay buffer is created.
4. At the beginning of each episode, the environment is initialized to S_0 .
5. At each simulation step, the agent selects an action a_t using the ε -greedy strategy.
6. The selected action is applied to the traffic light object via TraCI.
7. The environment transitions to a new state s_{t+1} , after which the reward R_t is calculated.

8. The transition $(s_t, a_t, R_t, s_{t+1}, d_t)$ is saved in the experience buffer.

9. Based on a random mini-sample from the buffer, the main network parameters are updated.

10. After a specified number of steps, the target network is updated: $\theta^- \leftarrow \theta$.

11. At the end of the episode, the value of ε is decreased.

The unique feature of the proposed method lies not only in the use of DQN, but also in the way the training signal is generated. The reward function takes into account vehicle wait times, pedestrian wait times, throughput, and penalties for excessive switching. Therefore, the agent is not trained to maximize vehicle flow alone. It is forced to find a compromise. Sometimes, it is more advantageous to maintain the current phase to relieve the accumulated vehicle queue. In other situations, it is better to switch earlier and prevent excessive pedestrian wait times. This is precisely the logic required for an urban intersection.

An additional advantage of the method is that it allows for the integration of different data sources. In a simulated environment, vehicle information can come from SUMO detectors, while in a more practical setting, a similar state vector can be generated based on camera data or computer vision models [25]. This allows the proposed approach to be considered as a basis for further transition from simulation testing to more realistic intelligent traffic management scenarios.

Thus, the proposed scheme differs from the basic DQN approach in the structure of the training signal. The agent is rewarded not only for reducing transport delays but also for reducing pedestrian wait times and for maintaining the stability of the phase control. When the pedestrian count exceeds a specified threshold, the contribution of pedestrian delays increases, allowing the control to adapt to local pedestrian flow accumulation.

4. Experimental part

The proposed method was tested using the SUMO microscopic modeling environment. A signalized intersection with four traffic directions was constructed. Each direction included three lanes, allowing for separate consideration of the traffic load on the approaches to the intersection. In addition to vehicles, pedestrian flows crossing the roadway at signalized crossings were added to the model.

Traffic signal control was performed via the TraCI interface. At each simulation step, the control module received data on the intersection state, generated an input vector for the DQN agent, and applied the selected action to the traffic signal. The state vector included the number of vehicles in the 12 lanes, the number of pedestrians in the crossing zone, and the current traffic signal phase. Thus, the agent made decisions based on the current traffic situation rather than on a predetermined schedule.

Fixed control was used as the baseline method. In this mode, phases switched according to a predetermined cycle and were independent of the observed number of vehicles or pedestrians. The comparison was conducted using the same network topology, the same traffic routes, and the same simulation duration. This allows us to evaluate the impact of the control algorithm, rather than differences in the experimental conditions.

The main parameters of the experimental setup are presented in Table 2. The parameter values must be the same for all compared runs.

Table 2

Parameters of the experimental setup

Parameter	Value
Simulation environment	SUMO
Network type	One controlled intersection
Number of directions	4
Number of lanes	12
Pedestrian Crossings	Controlled Crossings at Intersections
Phase diagram	Two main phases: movement in one direction and switching to the next phase
Minimum phase duration	10 s
Duration of one episode	1000 simulation steps
Simulation step	1 s
Number of training episodes	100
Number of experiment repetitions	5
Load Scenarios	Low, Medium, High Intensity
Basic Method	Fixed Traffic Light Cycle
Comparison method	DQN control with multi-component reward

The parameters of the DQN agent are given in Table 3. Their specification is important for reproducibility, since the quality of training significantly depends on the buffer size, learning rate, discount factor, and $\mathcal{E}$ reduction strategy.

Table 3

DQN agent parameters

Parameter	Value
Dimension of the input state	14
Number of actions	2
Hidden layers	2 layers of 64 neurons each
Activation function	ReLU
Optimizer	Adam
Learning rate	0.001
Discount factor γ	0.95
Replay buffer size	10000 transitions
The size of the mini-sample (batch size)	32
Minimum buffer size before training	1000 transitions
Loss function	Huber loss
Initial value $\mathcal{E}$	1.0
Minimum value $\mathcal{E}$	0.01
The rate of decrease $\mathcal{E}$	0.005
Target network update frequency	every 10 episodes

Routes were generated using standard SUMO tools. The model included cars, buses, trucks, and pedestrians. To test the algorithm's robustness, scenarios with varying traffic volumes were considered: low, medium, and high. In the baseline experiment, the results were aggregated across all runs, allowing for an averaged assessment of the method's effectiveness.

Four metrics were used to evaluate traffic quality:

- average vehicle waiting time;
- average pedestrian waiting time;
- total vehicle queue length;
- intersection throughput.

These metrics were chosen because they reflect different aspects of traffic signal operation. Vehicle waiting time characterizes the efficiency of vehicle traffic. Pedestrian waiting time in-

dicates whether gains are achieved at the expense of poor conditions for pedestrians. Queue length reflects the accumulation of congestion, while throughput measures how many vehicles pass through the intersection per unit of time.

The results of the comparison of fixed and adaptive control are presented in Table 4. The values are presented as averages over a series of independent runs with standard deviations. This format allows us to evaluate not only the average gain of the adaptive control but also the robustness of the results.

Table 4

Comparison of fixed and adaptive control, mean $\pm$ standard deviation

Metric	Fixed control	Adaptive control
Average waiting time for pedestrians, steps	45.0 $\pm$ 2.1	25.0 $\pm$ 1.6
Average waiting time for transport, steps	60.0 $\pm$ 2.8	42.0 $\pm$ 2.0
Total queue length, m	180.0 $\pm$ 7.4	120.0 $\pm$ 5.6
Throughput, veh/min	50.0 $\pm$ 1.9	65.0 $\pm$ 2.3

Additionally, the method was tested at different traffic levels. This breakdown is important, as a strategy effective at moderate traffic flow may perform less well at a saturated intersection. Table 5 shows the results for low, medium, and high traffic volumes.

Table 5

Comparison of control methods at different load levels, mean $\pm$ standard deviation

Scenario	Method	Pedestrian waiting, steps	Vehicle waiting, steps	Queue, m	Throughput, veh/min
Low load	DQN	31.0 $\pm$ 1.5	39.0 $\pm$ 2.0	96.0 $\pm$ 4.8	38.0 $\pm$ 1.4
Low load	Fix	20.0 $\pm$ 1.2	30.0 $\pm$ 1.7	72.0 $\pm$ 3.9	44.0 $\pm$ 1.6
Average load	DQN	45.0 $\pm$ 2.1	60.0 $\pm$ 2.8	180.0 $\pm$ 7.4	50.0 $\pm$ 1.9
Average load	Fix	25.0 $\pm$ 1.6	42.0 $\pm$ 2.0	120.0 $\pm$ 5.6	65.0 $\pm$ 2.3
High load	DQN	62.0 $\pm$ 3.4	84.0 $\pm$ 4.6	255.0 $\pm$ 11.2	56.0 $\pm$ 2.4
High load	Fix	38.0 $\pm$ 2.7	61.0 $\pm$ 3.5	178.0 $\pm$ 8.9	72.0 $\pm$ 2.8

Table 5 shows that as load increases, the absolute values of delays and queue lengths increase, but the adaptive scheme maintains control over the intersection. The effect is most noticeable in medium- and high-load scenarios, where the fixed cycle leads to queue accumulation more quickly.

For a visual comparison of these same indicators, the diagram shown in Figure 1 is shown. It demonstrates that adaptive control reduces the values of metrics related to waiting and queues while simultaneously increasing throughput.

Table 4 and Figure 1 show that adaptive control improves all the metrics analyzed. Average pedestrian wait time is reduced from 45 to 25 steps, a reduction of approximately 44%. Vehicle wait time is reduced from 60 to 42 steps, a 30% reduction. The total queue length is reduced from 180 to 120 meters. Throughput increases from 50 to 65 vehicles per minute.

To evaluate the learning process, the total reward dynamics were plotted across episodes. This graph allows us to verify whether the agent is developing a stable control strategy, rather than simply experiencing random improvements in individual runs.

5. Analysis of results




Fig. 1. Comparison of the performance indicators of fixed and adaptive control




Fig. 2. Dynamics of the total reward of the DQN agent by training episodes

As can be seen from Figure 2, the reward value changes unstably in the initial episodes, which is due to the high proportion of random actions in the ϵ -greedy strategy. As ϵ decreases, the agent more frequently utilizes its accumulated experience, and the total reward gradually stabilizes. This indicates the development of a more stable control policy.

The obtained values should be considered the result of an initial simulation test. They demonstrate the viability of the proposed approach but do not constitute exhaustive proof of its superiority under all conditions. For a more rigorous evaluation, it is necessary to expand the experiment: add several load scenarios, compare the method not only with a fixed cycle but also with other adaptive or RL-based algorithms, and also report the spread of results across independent runs.

This result is due to the fact that the agent does not follow a fixed cycle but reacts to the current state of the intersection. If a queue forms in one direction, the strategy can hold the corresponding phase longer. If pedestrians accumulate at a crossing, the reward function increases the weight of pedestrian waiting time, and the agent is incentivized to give a green light more quickly. This improves not only traffic but also pedestrian performance.

The results show that adaptive control reduces delays for both vehicles and pedestrians. This is an important point: the improvement is achieved not by redistributing waiting time from one group of road users to another, but by more flexible use of traffic light phases.

A fixed cycle predetermines the signal duration and does not react to actual queue buildup. A DQN agent, in contrast, uses the current state of the intersection and can change its behavior depending on the situation.

The standard deviation in Table 4 allows us to assess the robustness of the method. If the spread of values for adaptive control remains moderate, we can conclude not only that the average result has improved but also that the effect is reproducible. This is especially important for reinforcement learning problems, where the final policy may depend on the initial network initialization, the order of observations, and random actions during the exploration phase.

Dividing the experiments by load scenarios reveals the conditions under which adaptive control yields the greatest gains. At low traffic loads, the difference between the methods is usually smaller, since the fixed cycle does not yet introduce significant losses. At medium and high loads, the advantage of the DQN agent becomes more noticeable: the system encounters queues and pedestrians more frequently, providing more opportunities for adaptive phase reallocation.

The most noticeable improvement is observed in pedestrian waiting times. This is due to the fact that pedestrian flow is explicitly included in the environment state and the reward function. As the number of pedestrians in the crossing zone increases, the contribution of pedestrian delay to the overall learning signal increases. As a result, it becomes unprofitable for the agent to hold the vehicle phase for a long time if a group of people has already formed at the crossing. Simple logic, but for an urban intersection, it is crucial.

The reduction in vehicle waiting times is explained by another aspect of the same adaptivity. The agent takes lane congestion into account and can maintain the current phase if a significant flow of vehicles is passing through it. In a fixed-time control system, this is not possible: switching occurs according to a schedule, even if one direction is already empty and the other is congested. Therefore, some of the green time is wasted. In the adaptive mode, it is used more efficiently.

The reduction in the total queue length is due to the agent not only reacting to the accumulated delay but also gradually learning to avoid states in which the queue begins to grow rapidly. The experience replay buffer allows for the use of previous situations when updating the model, and the target network stabilizes learning. Therefore, the strategy becomes not simply reactive, but more stable over time.

The penalty for phase switching is particularly noteworthy. Without such a restriction, the agent might choose excessively frequent signal changes, attempting to instantly react to every small flow change. In practice, this is bad behavior: it creates instability, increases time losses during transition phases, and can degrade safety. Adding a penalty makes the policy more relaxed. The agent switches phases only when it provides a significant benefit to the overall reward function.

However, the results should not be overestimated. The experiment was conducted for a single signalized intersection, so it cannot yet be concluded that the same policy, without modification, would be effective for a network of intersections. In a multi-intersection system, additional effects arise: queue propagation between nodes, the need for phase coordination, the influence of adjacent traffic lights, and the heterogeneity of the road topology. This is a separate issue.

Another limitation is related to the quality of the input data. In the simulation, the agent receives fairly accurate information on the number of vehicles and pedestrians. In a real environment, this data may be obtained from cameras or other sensors, meaning it will contain detection errors, omissions, false alarms, and transmission delays. Such uncertainty can impact the quality of control. Therefore, before practical application, the method needs to be further tested under noisy observation conditions.

Despite these limitations, the experiment confirms the viability of the proposed approach. The multi-component reward function allows the agent to consider not just a single metric, but several related objectives: vehicle delays, pedestrian waiting times, throughput, and phase switching stability. This makes the system's behavior more balanced than with fixed-priority control.

Conclusion

This paper examines the problem of adaptive traffic signal control, simultaneously accounting for vehicle and pedestrian flows. A reinforcement learning-based method is proposed, in which the control agent uses intersection conditions, including lane occupancy, pedestrian count, and the current traffic signal phase. A Deep Q-Network algorithm is used to select control actions.

The key element of the method is a multi-component reward function. It includes vehicle delays, pedestrian waiting times, intersection capacity, and a penalty for excessive phase changes. This formulation allows the agent to not simply reduce vehicle queues but also to seek a more balanced control strategy. This is important for urban environments, where the effectiveness of traffic signal control cannot be assessed solely by transport metrics.

Experimental testing in the SUMO environment demonstrated the advantages of adaptive control over fixed-cycle control. The average pedestrian wait time decreased from 45 to 25 steps, vehicle wait time from 60 to 42 steps, the total queue length decreased from 180 to 120 meters, and throughput increased from 50 to 65 vehicles per minute. These results demonstrate that incorporating the pedestrian component into the reward function does influence agent behavior and helps avoid a vehicle-centric control strategy.

However, the work has limitations. The experiments were conducted for a single signalized intersection in a simulation environment, so further testing should include more complex road networks, multiple interacting traffic signals, and scenarios with noisy input data. A promising direction is to expand the method to multi-agent settings, as well as integrate computer vision data to generate environmental state in conditions closer to real urban infrastructure.

References

[1] K. A. Polyantseva, M. G. Gorodnichev, M. S. Moseva, and T. D. Potapchenko, "On the Applicability of Neural Networks in the Tasks of Detecting Dangerous Movement," in *Proc. Wave Electronics and its Application*

in *Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russia, 2019, p. 8840654, doi: 10.1109/WECONF.2019.8840654.

[2] M. G. Gorodnichev, K. A. Polyantseva, and M. V. Yashina, "Informational Aspects of Automated Monitoring of Dangerous Driving," in *Proc. Systems of Signals Generating and Processing in the Field of on Board Communications (SOSG)*, Moscow, Russia, 2019, p. 8706721, doi: 10.1109/SOSG.2019.8706721.

[3] K. Polyantseva, M. Gorodnichev, Y. Mitrokhin, and M. Moseva, "On the Problem of Developing a Realistic Road Infrastructure Simulator for Reinforced Learning," in *Proc. Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2023, pp. 1-8, doi: 10.1109/WECONF57201.2023.10147983.

[4] M. Noacen, A. Naik, L. Goodman, J. Crebo, T. Abrar, Z. S. H. Abad, A. L. C. Bazzan, and B. Far, "Reinforcement learning in urban network traffic signal control: A systematic literature review," *Expert Systems with Applications*, vol. 199, p. 116830, 2022, doi: 10.1016/j.eswa.2022.116830.

[5] H. Zhao, C. Dong, J. Cao, and Q. Chen, "A survey on deep reinforcement learning approaches for traffic signal control," *Engineering Applications of Artificial Intelligence*, vol. 133, Part A, p. 108100, 2024, doi: 10.1016/j.engappai.2024.108100.

[6] S. Bouktif, A. Cheniki, A. Ouni, and H. El-Sayed, "Deep reinforcement learning for traffic signal control with consistent state and reward design approach," *Knowledge-Based Systems*, vol. 267, p. 110440, 2023, doi: 10.1016/j.knosys.2023.110440.

[7] C. Cai and M. Wei, "Adaptive urban traffic signal control based on enhanced deep reinforcement learning," *Scientific Reports*, vol. 14, p. 14116, 2024, doi: 10.1038/s41598-024-64885-w.

[8] L. Wang, G. Zhang, Q. Yang, and T. Han, "An adaptive traffic signal control scheme with Proximal Policy Optimization based on deep reinforcement learning for a single intersection," *Engineering Applications of Artificial Intelligence*, vol. 149, p. 110440, 2025, doi: 10.1016/j.engappai.2025.110440.

[9] Q. Jiang, M. Qin, S. Shi, W. Sun, and B. Zheng, "Multi-agent reinforcement learning for traffic signal control through universal communication method," in *Proc. 31st International Joint Conference on Artificial Intelligence (IJCAI-ECAI)*, Vienna, Austria, 2022, pp. 3854-3860.

[10] X. Song, B. Zhou, and D. Ma, "Cooperative Traffic Signal Control Through A Counterfactual Multi-Agent Deep Actor Critic Approach," *SSRN*, 2022, doi: 10.2139/ssrn.4021959.

[11] S. Yang, "Hierarchical graph multi-agent reinforcement learning for traffic signal control," *Information Sciences*, vol. 634, pp. 55-72, 2023, doi: 10.1016/j.ins.2023.03.087.

[12] Y. Bie, Y. Ji, and D. Ma, "Multi-agent Deep Reinforcement Learning collaborative Traffic Signal Control method considering intersection heterogeneity," *Transportation Research Part C: Emerging Technologies*, vol. 164, p. 104663, 2024, doi: 10.1016/j.trc.2024.104663.

[13] T. Wang, Z. Zhu, J. Zhang, J. Tian, and W. Zhang, "A large-scale traffic signal control algorithm based on multi-layer graph deep reinforcement learning," *Transportation Research Part C: Emerging Technologies*, vol. 162, p. 104582, 2024, doi: 10.1016/j.trc.2024.104582.

[14] J. Bao, C. Wu, Y. Lin et al., "A scalable approach to optimize traffic signal control with federated reinforcement learning," *Scientific Reports*, vol. 13, p. 19184, 2023, doi: 10.1038/s41598-023-46074-3.

[15] M. Li, X. Pan, C. Liu et al., "Federated deep reinforcement learning-based urban traffic signal optimal control," *Scientific Reports*, vol. 15, p. 11724, 2025, doi: 10.1038/s41598-025-91966-1.

[16] M. Yazdani, M. Sarvi, S. A. Bagloee, N. Nassir, J. Price, and H. Parineh, "Intelligent vehicle pedestrian light (IVPL): A deep reinforcement learning approach for traffic signal control," *Transportation Research Part C: Emerging Technologies*, vol. 149, p. 103991, 2023, doi: 10.1016/j.trc.2022.103991.

[17] A. Ren, G. Zhang, C. Chang, and D. Huang, "Two-step deep reinforcement learning for traffic signal control to improve pedestrian

safety using connected vehicle data," *Accident Analysis & Prevention*, vol. 222, p. 108161, 2025, doi: 10.1016/j.aap.2025.108161.

[18] D. Garg, M. Chli, and G. Vogiatzis, "Fully-Autonomous, Vision-based Traffic Signal Control: from Simulation to Reality," in *Proc. 21st International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*, Online, 2022, pp. 1-9.

[19] G. Zhang, X. Zhao, and G. Wang, "End-to-End Reinforcement Learning for Traffic Signal Control: Real-Time Video to Signal Decisions," 2024. [Online]. Available: <https://openreview.net/forum?id=eM5dar35Ys>

[20] P. Michailidis, I. Michailidis, C. R. Lazaridis, and E. Kosmatopoulos, "Traffic Signal Control via Reinforcement Learning: A Review on Applications and Innovations," *Infrastructures*, vol. 10, p. 114, 2025, doi: 10.3390/infrastructures10050114.

[21] M. Elharoun, S. El-Badawy, E. Shwaly, and U. Shahdah, "Adaptive traffic signal control using deep reinforcement learning: A multi-objective approach for single and multi-intersection scenarios,"

IATSS Research, vol. 49, pp. 481-492, 2025, doi: 10.1016/j.iatssr.2025.10.004.

[22] A. Saadi, N. Abghour, Z. Chiba et al., "A survey of reinforcement and deep reinforcement learning for coordination in intelligent traffic light control," *Journal of Big Data*, vol. 12, p. 84, 2025, doi: 10.1186/s40537-025-01104-x.

[23] D. V. Gadasin and A. V. Shvedov, "Application of the transportation problem for load balancing under fuzzy initial data," *T-Comm*, vol. 18, no. 1, pp. 13-20, 2024, doi: 10.36724/2072-8735-2024-18-1-13-20.

[24] A. V. Shvedov, D. V. Gadasin, and A. V. Alyoshintsev, "Segment routing in data transmission networks," *T-Comm*, vol. 16, no. 5, pp. 56-62, 2022, doi: 10.36724/2072-8735-2022-16-5-56-62.

[25] D. V. Gadasin, A. V. Shvedov, and I. A. Kuzin, "Three-dimensional reconstruction of an object from a single image using deep convolutional neural networks," *T-Comm*, vol. 16, no. 7, pp. 29-35, 2022, doi: 10.36724/2072-8735-2022-16-7-29-35.

АДАПТИВНОЕ УПРАВЛЕНИЕ СВЕТОФОРАМИ НА ОСНОВЕ ОБУЧЕНИЯ С ПОДКРЕПЛЕНИЕМ С УЧЕТОМ ПОТОКОВ ТРАНСПОРТНЫХ СРЕДСТВ И ПЕШЕХОДОВ

Полянцева Ксения Андреевна, Московский технический университет связи и информатики, Москва, Россия,
k.a.poliantseva@mtuci.ru

Городничев Михаил Геннадьевич, Московский технический университет связи и информатики, Москва, Россия,
m.g.gorodnichev@mtuci.ru

Кулагин Владимир Петрович, Московский технический университет связи и информатики, Москва, Россия,
v.p.kulagin@mtuci.ru

Аннотация

В работе рассматривается задача адаптивного управления светофорным объектом с совместным учётом транспортных и пешеходных потоков. Предложен метод, основанный на алгоритме Deep Q-Network, в котором агент принимает решение о сохранении или переключении фазы светофора на основе текущего состояния перекрёстка. Состояние включает загруженность полос движения, количество пешеходов в зоне перехода и текущую фазу регулирования. Основной вклад работы связан с разработкой многокомпонентной адаптивной функции вознаграждения. В неё включены задержки транспортных средств, ожидание пешеходов, пропускная способность перекрёстка и штраф за избыточные переключения фаз. При накоплении пешеходов в зоне перехода пешеходная компонента усиливается, что позволяет агенту избежать автомобиль-центричной стратегии управления и учитывать интересы разных участников движения. Экспериментальная проверка выполнена в среде микроскопического моделирования SUMO. Предложенный метод сравнивался с фиксированным управлением светофором. Полученные результаты показали снижение среднего времени ожидания пешеходов и транспортных средств, сокращение длины очередей и рост пропускной способности перекрёстка. Результаты подтверждают, что обучение с подкреплением в сочетании с адаптивной функцией вознаграждения может быть использовано для более гибкого и сбалансированного управления городским перекрестком.

Ключевые слова: адаптивное управление светофорами, обучение с подкреплением, Deep Q-Network, транспортные потоки, пешеходные потоки, SUMO, интеллектуальные транспортные системы

Литература

1. Polyantseva K. A., Gorodnichev M. G., Moseva M. S., Potapchenko T. D. On the Applicability of Neural Networks in the Tasks of Detecting Dangerous Movement // *Proc. Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russia, 2019, p. 8840654, doi: 10.1109/WECONF.2019.8840654.
2. Gorodnichev M. G., Polyantseva K. A., Yashina M. V. Informational Aspects of Automated Monitoring of Dangerous Driving // *Proc. Systems of Signals Generating and Processing in the Field of on Board Communications (SOSG)*, Moscow, Russia, 2019, p. 8706721, doi: 10.1109/SOSG.2019.8706721.

3. Polyantseva K., Gorodnichev M., Mitrokhin Y., Moseva M. On the Problem of Developing a Realistic Road Infrastructure Simulator for Reinforced Learning // *Proc. Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2023, pp. 1-8, doi: 10.1109/WECONF57201.2023.10147983.
4. Noaen M., Naik A., Goodman L., Crebo J., Abrar T., Abad Z. S. H., Bazzan A. L. C., Far B. Reinforcement learning in urban network traffic signal control: A systematic literature review // *Expert Systems with Applications*, vol. 199, p. 116830, 2022, doi: 10.1016/j.eswa.2022.116830.
5. Zhao H., Dong C., Cao J., Chen Q. A survey on deep reinforcement learning approaches for traffic signal control // *Engineering Applications of Artificial Intelligence*, vol. 133, Part A, p. 108100, 2024, doi: 10.1016/j.engappai.2024.108100.
6. Bouktif S., Cheniki A., Ouni A., El-Sayed H. Deep re-inforcement learning for traffic signal control with consistent state and reward design approach // *Knowledge-Based Systems*, vol. 267, p. 110440, 2023, doi: 10.1016/j.knosys.2023.110440.
7. Cai C., Wei M. Adaptive urban traffic signal control based on enhanced deep reinforcement learning // *Scientific Reports*, vol. 14, p. 14116, 2024, doi: 10.1038/s41598-024-64885-w.
8. Wang L., Zhang G., Yang Q., Han T. An adaptive traffic signal control scheme with Proximal Policy Optimization based on deep reinforcement learning for a single intersection // *Engineering Applications of Artificial Intelligence*, vol. 149, p. 110440, 2025, doi: 10.1016/j.engappai.2025.110440.
9. Jiang Q., Qin M., Shi S., Sun W., Zheng B. Multi-agent reinforcement learning for traffic signal control through universal communication method // *Proc. 31st International Joint Conference on Artificial Intelligence (IJCAI-ECAL)*, Vienna, Austria, 2022, pp. 3854-3860.
10. Song X., Zhou B., Ma D. Cooperative Traffic Signal Control Through A Counterfactual Multi-Agent Deep Actor Critic Approach // *SSRN*, 2022, doi: 10.2139/ssrn.4021959.
11. Yang S. Hierarchical graph multi-agent reinforcement learning for traffic signal control // *Information Sciences*, vol. 634, pp. 55-72, 2023, doi: 10.1016/j.ins.2023.03.087.
12. Bie Y., Ji Y., Ma D. Multi-agent Deep Reinforcement Learning collaborative Traffic Signal Control method considering intersection heterogeneity // *Transportation Research Part C: Emerging Technologies*, vol. 164, p. 104663, 2024, doi: 10.1016/j.trc.2024.104663.
13. Wang T., Zhu Z., Zhang J., Tian J., Zhang W. A large-scale traffic signal control algorithm based on multi-layer graph deep reinforcement learning // *Transportation Research Part C: Emerging Technologies*, vol. 162, p. 104582, 2024, doi: 10.1016/j.trc.2024.104582.
14. Bao J., Wu C., Lin Y. et al., "A scalable approach to opti-mize traffic signal control with federated reinforcement learning // *Scientific Reports*, vol. 13, p. 19184, 2023, doi: 10.1038/s41598-023-46074-3.
15. Li M., Pan X., Liu C. et al., "Federated deep reinforcement learning-based urban traffic signal optimal control // *Scientific Reports*, vol. 15, p. 11724, 2025, doi: 10.1038/s41598-025-91966-1.
16. Yazdani M., Sarvi M., Bagloee S.A., Nassir N., Price J., Parineh H. Intelligent vehicle pedestrian light (IVPL): A deep reinforcement learning approach for traffic signal control // *Transportation Research Part C: Emerging Technologies*, vol. 149, p. 103991, 2023, doi: 10.1016/j.trc.2022.103991.
17. Ren A., Zhang G., Chang C., Huang D. Two-step deep reinforcement learning for traffic signal control to improve pe-destrian safety using connected vehicle data // *Accident Analysis & Prevention*, vol. 222, p. 108161, 2025, doi: 10.1016/j.aap.2025.108161.
18. Garg D., Chli M., Vogiatzis G. Fully-Autonomous, Vision-based Traffic Signal Control: from Simulation to Reality // *Proc. 21st International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*, Online, 2022, pp. 1-9.
19. Zhang G., Zhao X., Wang G. End-to-End Reinforce-ment Learning for Traffic Signal Control: Real-Time Video to Signal Decisions // 2024. [Online]. Available: <https://openreview.net/forum?id=eM5dar35Ys>
20. Michailidis P., Michailidis I., Lazaridis C. R., Kosmatopoulos E. Traffic Signal Control via Reinforcement Learning: A Review on Applications and Innovations // *Infrastructures*, vol. 10, p. 114, 2025, doi: 10.3390/infrastructures10050114.
21. Elharoun M., El-Badawy S., Shwaly E., Shahdah U. Adaptive traffic signal control using deep reinforcement learning: A multi-objective approach for single and multi-intersection scenarios // *IATSS Research*, vol. 49, pp. 481-492, 2025, doi: 10.1016/j.iatssr.2025.10.004.
22. Saadi A., Abghour N., Chiba Z. et al., "A survey of rein-forcement and deep reinforcement learning for coordination in intelligent traffic light control // *Journal of Big Data*, vol. 12, p. 84, 2025, doi: 10.1186/s40537-025-01104-x.
23. Гадасин Д.В., Шведов А.В. Применение транспортной задачи для балансировки нагрузки в условиях нечеткости исходных данных // *Т-Comm: Телекоммуникации и транспорт*. 2024. -Т. 18, № 1. С. 13-20. DOI 10.36724/2072-8735-2024-18-1-13-20.
24. Shvedov A.V., Gadasin D.V., Alyoshintsev A.V. Segment routing in data transmission networks // *Т-Comm: Телекоммуникации и транспорт*, vol. 16, no. 5, pp. 56-62, 2022, doi: 10.36724/2072-8735-2022-16-5-56-62.
25. Гадасин Д.В., Шведов А.В., Кузин И.А. Трехмерная реконструкции объекта по одному изображению с использованием глубоких свёрточных нейронных сетей // *Т-Comm: Телекоммуникации и транспорт*. 2022. Т. 16, № 7. С. 29-35. DOI 10.36724/2072-8735-2022-16-7-29-35.

Информация об авторах:

Полянцева Ксения Андреевна, кандидат технических наук, Московский технический университет связи и информатики, Москва, Россия

Городничев Михаил Геннадьевич, кандидат технических наук, доцент, Московский технический университет связи и информатики, Москва, Россия

Кулагин Владимир Петрович, доктор технических наук, профессор, Московский технический университет связи и информатики, Москва, Россия

УПРАВЛЕНИЕ ИНФОКОММУНИКАЦИЯМИ

Борис Гольдштейн
Александр Гольдштейн



УПРАВЛЕНИЕ ИНФОКОММУНИКАЦИЯМИ



Стремительность развития инфокоммуникаций и скорость появления новых поколений сетей связи уже не удивляет, в отличие от сервисов и услуг, которые начинают соперничать с научно-фантастическими фильмами. Постепенно сети пятого поколения и их возможности становятся нормой, а поколение B5G и 6G уже готовятся их сменить, предлагая сумасшедшие скорости, сверхнизкую задержку, распределенный искусственный интеллект. Умные города, иммерсивная дополненная реальность и кибербезопасность нового уровня – сети будущего создают основу для мира, в котором цифровая и физическая реальности сливаются в единую киберфизическую.

При этом эти новые сети связи, требуют новых подходов, систем и средств управления сетью, адекватных им и решаемых ими задачам. Новая книга "Управление инфокоммуникациями" охватывает основные технологии, научные достижения и практические применения управления современными телекоммуникациями.

Авторы анализируют практические вопросы управления сложнейшей современной телекоммуникационной инфраструктурой, показывая трансформацию систем

управления – от традиционных OSS/BSS к интеллектуальным, распределённым, облачно-ориентированным платформам, использующим искусственный интеллект, цифровые двойники, аналитику больших данных и автоматизацию полного жизненного цикла сервисов и ресурсов, показывают, как меняется сама философия эксплуатации: от реактивного реагирования на аварии к предиктивному управлению, автоматическому предотвращению инцидентов и оптимизации ресурсов в реальном времени.

Читатель сможет получить не только теоретическое представление о принципах построения современных систем управления, но и практические инструменты понимания процессов инвентаризации ресурсов, управления услугами, активами, качеством обслуживания, эксплуатацией и развитием сети.

На страницах книги рассматривается роль управления в условиях виртуализации сетевых функций, перехода к cloud-native архитектурам, сетевому slicing, edge-инфраструктурам и внедрению интеллектуальных механизмов самонастраивающихся сетей.

Книга будет полезна широкому кругу читателей – инженерам операторов связи, разработчикам OSS/BSS-платформ, архитекторам сетей, исследователям, преподавателям и студентам профильных вузов. Она может служить как современным учебным пособием, так и практическим руководством для специалистов, участвующих в создании и эксплуатации сетей нового поколения.



Борис Гольдштейн, доктор технических наук, профессор, окончил с отличием Санкт-Петербургский университет телекоммуникаций (СПбГУТ) им. проф. М. А. Бонч-Бруевича, защитил кандидатскую и докторскую диссертации в области телекоммуникаций. Занимался разработкой архитектуры, ПО и протоколов мультисервисных сетей NGN/IMS/LTE/5G/6G. Много лет был заместителем директора по науке Ленинградского отраслевого НИИ связи (ЛОНИИС), профессором СПбГУТ. Более 20 лет заведовал кафедрой инфокоммуникационных сетей. Его аспиранты успешно работают в сетях связи разных стран на четырех континентах.

Автор более 350 статей, 30 книг, в том числе «Evolution of Telecommunication Protocols», «IP-телефония», «Инфокоммуникационные сети и системы» и др., 30 патентов. Сооснователь Научно-исследовательских центров Протей, Аргус, Севентест. Член Исследовательской комиссии 10 ITU-T и оргкомитетов ряда международных симпозиумов, приглашённый редактор института IEEE, член редакционных коллегий научных журналов, академик Международной академии связи (МАС), имеет звание «Мастер связи».



Александр Гольдштейн, доктор технических наук, профессор СПбГУТ им. проф. М. А. Бонч-Бруевича, генеральный директор и сооснователь НТЦ АРГУС. Окончил СПбГУТ в 2001 г., в 2004 г. защитил кандидатскую диссертацию по туннелированию мультимедийного трафика в MPLS-сетях. В 2005 г. получил второе высшее образование по экономике и финансам. В 2019 г. защитил докторскую диссертацию «Модели и методы управления инфокоммуникационными сетями».

Автор более 100 публикаций, в том числе книг «Технологии и протоколы MPLS», «Softswitch», «Протоколы Megaco/H.248» и учебных пособий по автоматизации бизнес-процессов операторов связи. Профессиональные интересы — управление и эксплуатация сетей 5G, искусственный интеллект, OSS/BSS и стандарты TMF/ODA.



191036, Санкт-Петербург,
Голосарная ул., 20
Тел.: (812) 717-10-50,
339-54-17, 339-54-29
E-mail: mail@bhv.ru
Internet: www.bhv.ru



ks.su.ru
protel.ru



seventest.ru
argus.ru

организаторы:
RUSSIA SECTION CAS CHAPTER
INSTITUTE OF RADIO AND INFORMATION SYSTEMS (IRIS)

МЕЖДУНАРОДНАЯ КОНФЕРЕНЦИЯ
**“2026 Systems of Signal Synchronization, Generating
and Processing in Telecommunications”**
SYNCHROINFO

30 июня – 3 июля 2026
г. Петрозаводск, Россия

The papers which are discussed at the conference can be divided into the following chapters:

- 1) Synchronization Systems and Devices;**
- 2) Signal Generating and Shaping Devices;**
- 3) Signal Processing Devices.**
- 4) Special chapter: “Problems of microwave electronics” named after V.A. Solntsev**
- 5) Photonics and mathematics for moving objects**
- 6) Synchronization of information technology processes and technological controlling**
- 7) Optical Methods and Devices**



All accepted and presented Papers following the conference will be submitted for inclusion into IEEE Xplore

Materials are available in English

<http://media-publisher.ru/en/conference/>