



**ВЕСТНИК РОССИЙСКОГО УНИВЕРСИТЕТА ДРУЖБЫ НАРОДОВ.
СЕРИЯ: ИНЖЕНЕРНЫЕ ИССЛЕДОВАНИЯ**

2025 Том 26 № 3

DOI: 10.22363/2312-8143-2025-26-3

<http://journals.rudn.ru/engineering-researches>

Научный журнал

Издается с 2000 г.

Издание зарегистрировано Федеральной службой по надзору в сфере связи,
информационных технологий и массовых коммуникаций (Роскомнадзор)

Свидетельство о регистрации ПИ № ФС 77-61174 от 30.03.2015 г.

Учредитель: Федеральное государственное автономное образовательное учреждение высшего образования
«Российский университет дружбы народов имени Патриса Лумумбы»

Главный редактор

Разумный Юрий Николаевич — доктор технических наук, профессор, директор инженерной академии, заведующий кафедрой механики и процессов управления инженерной академии, Российский университет дружбы народов, Москва, Россия

Заместитель главного редактора

Резник Сергей Васильевич — доктор технических наук, профессор, заведующий кафедрой СМ-13 «Ракетно-космические композитные конструкции», факультет «Специальное машиностроение», Московский государственный технический университет имени Н.Э. Баумана, Москва, Россия

Ответственный секретарь

Агасиева Светлана Викторовна — кандидат технических наук, доцент кафедры нанотехнологий и микросистемной техники, инженерная академия, Российский университет дружбы народов, Москва, Россия

Члены редакционной коллегии

Агравал Бридж — профессор, Военно-морская школа, Монтерей, США

Алифанов Олег Михайлович — академик РАН, доктор технических наук, профессор, Московский авиационный институт (национальный исследовательский университет), Москва, Россия

Варатараджу Ренугант — профессор, Университет Путра Малайзия, Серданг, Малайзия

Василе Массимилиано Л. — профессор, Университет Стратклайда, Глазго, Великобритания

Вивiani Антонио — профессор, Университет Кампани «Луиджи Ванвители», Неаполь, Италия

Гасбарри Паоло — профессор, Римский университет «Ла Сапиенца», Рим, Италия

Герман Анна — профессор, Университет Бейра-Интернор, Ковильян, Португалия

Гитас Иоаннис Зоис — профессор, Университет Аристотеля в Салониках, Салоники, Греция

Грациани Филиппо — почетный профессор, Римский университет «Ла Сапиенца», Рим, Италия

Гурфил Пини — почетный профессор, Израильский технологический институт, Хайфа, Израиль

Джеа Мориба — доцент, Техасский университет в Остине, Остин, США

Джесента Джанкарло — профессор, Туринский политехнический институт, Турин, Италия

Кавазутти Дзюньитиро — профессор, Японское агентство аэрокосмических исследований, Токио, Япония

Калугин Владимир Тимофеевич — доктор технических наук, профессор, Московский государственный технический университет имени Н.Э. Баумана, Москва, Россия

Капустин Владимир Михайлович — доктор технических наук, профессор, Российский государственный университет нефти и газа имени И.М. Губкина, Москва, Россия

Кузнецов Николай Борисович — профессор, Геологический институт РАН, Москва, Россия

Линарес Ричард — профессор, Массачусетский технологический институт, Кембридж, США

Матюшин Максим Михайлович — доктор технических наук, Центр управления полетами ЦНИИмаш, ГК «Роскосмос», Королев, Россия

Медведев Андрей Всеволодович — доктор физико-математических наук, член-корреспондент СО РАН, Институт солнечно-земной физики СО РАН, Иркутск, Россия

Мисра Арун — профессор, Университет Макгилла, Монреаль, Канада

Мортари Даниэле — профессор, Техасский университет А&М, Колледж-Стейшн, США

Мохаммед Сейду О. — профессор, Национальное агентство по космическим исследованиям и развитию, Абуджа, Нигерия

Палмерини Джованни — профессор, Римский университет «Ла Сапиенца», Рим, Италия

Петухов Вячеслав Георгиевич — доктор технических наук, член-корреспондент РАН, Московский авиационный институт (национальный исследовательский университет), Москва, Россия

Попков Юрий Соломонович — академик РАН, доктор технических наук, профессор, Институт системного анализа, ФИЦ «Информатика и управление» РАН, Москва, Россия

Попов Гарри Алексеевич — академик РАН, доктор технических наук, профессор, директор Научно-исследовательского института прикладной механики и электродинамики, Московский авиационный институт (национальный исследовательский университет), Москва, Россия

Прадо Антонио — профессор, Национальный институт космических исследований, Сан-Жозе-дус-Кампус, Бразилия

Редько Иван Яковлевич — доктор технических наук, профессор, Энергетический институт имени Г.М. Кржижановского, Москва, Россия

Спенсер В. Дэвид — профессор, Университет штата Пенсильвания, Юниверсити-Парк, США

Фурфаро Роберто — профессор, Университет Аризоны, Тусон, США

Челани Фабио — профессор, Римский университет «Ла Сапиенца», Рим, Италия

Черн Рок Ченг-Шинг — профессор, Университет Райерсона, Торонто, Канада

Ясака Тэцуо — почетный профессор, Университет Кюсю, Фукуока, Япония

**ВЕСТНИК РОССИЙСКОГО УНИВЕРСИТЕТА ДРУЖБЫ НАРОДОВ.
СЕРИЯ: ИНЖЕНЕРНЫЕ ИССЛЕДОВАНИЯ**

ISSN 2312-8143 (Print); ISSN 2312-8151 (Online)

Сайт журнала: <http://journals.rudn.ru/engineering-researches> (открытый доступ) 

Периодичность: 4 выпуска в год (ежеквартально).

Языки: русский, английский.

Журнал индексируют: РИНЦ, DOAJ, Ulrich's Periodicals Directory, Cyberleninka, Google Scholar, WorldCat, Dimensions, ResearchBib, Lens, Research4Life, JournalTOCs, British Library, Bodleian Libraries (University of Oxford), Ghent University Library.

Цель и тематика

Журнал «Вестник Российского университета дружбы народов. Серия: Инженерные исследования» — периодическое международное рецензируемое научное издание в области авиационной и ракетно-космической техники, машиностроения. Журнал является международным по составу редакционной коллегии, авторам и тематике публикаций. В журнале публикуются результаты оригинальных научных исследований российских и зарубежных ученых.

Цели журнала:

- содействие развитию российских и зарубежных инженерных школ;
- продвижение и внедрение в практику современных перспективных разработок в указанных областях;
- научный обмен и сотрудничество между учеными.

Журнал входит в перечень изданий, публикации которых учитываются Высшей аттестационной комиссией России (ВАК РФ) при защите диссертаций на соискание ученых степеней кандидата и доктора наук по специальностям:

- 2.3.1. Системный анализ, управление и обработка информации (технические науки);
- 2.3.4. Управление в организационных системах (технические науки);
- 2.5.6. Технология машиностроения (технические науки);
- 2.5.13. Проектирование, конструкция и производство летательных аппаратов (технические науки);
- 2.5.14. Прочность и тепловые режимы летательных аппаратов (технические науки);
- 2.5.16. Динамика, баллистика, управление движением летательных аппаратов (технические науки).

Журнал адресован научным работникам, инженерам, аспирантам.

Выпуски журнала в полнотекстовом виде, правила оформления статей и дополнительная информация размещены на сайте <http://journals.rudn.ru/engineering-researches>

Редколлегия журнала строго придерживается международных стандартов публикационной этики, сформулированных в документе COPE (Committee on Publication Ethics): <http://publicationethics.org>

Редактор *И.Л. Панкратова*

Редактор англоязычных текстов *А.С. Корзин, Е.Ф. Шалеева, Н.А. Алексеева*
Компьютерная верстка *Н.В. Маркеловой*

Адрес редакции:

Российская Федерация, 115419, Москва, ул. Орджоникидзе, д. 3
Тел.: +7 (495) 955-07-16; e-mail: publishing@rudn.ru

Адрес редакционной коллегии журнала

«Вестник Российского университета дружбы народов. Серия: Инженерные исследования»:

Российская Федерация, 115419, Москва, ул. Орджоникидзе, д. 3
Тел.: +7 (495) 955-07-92; e-mail: engi@rudn.ru

Подписано в печать 23.09.2025. Выход в свет 30.09.2025. Формат 60×84/8.

Бумага офсетная. Печать офсетная. Гарнитура «Times New Roman».

Усл. печ. л. 15,32. Тираж 500 экз. Заказ № 1254. Цена свободная.

Федеральное государственное автономное образовательное учреждение высшего образования

«Российский университет дружбы народов имени Патриса Лумумбы»

Российская Федерация, 117198, Москва, ул. Миклухо-Маклая, д. 6

Отпечатано в типографии ИПК РУДН им. Патриса Лумумбы

Российская Федерация, 115419, Москва, ул. Орджоникидзе, д. 3

Тел.: +7 (495) 955-08-61; e-mail: publishing@rudn.ru



RUDN JOURNAL OF ENGINEERING RESEARCH

2025 Volume 26 Number 3

DOI: 10.22363/2312-8143-2025-26-3

<http://journals.rudn.ru/engineering-researches>

Founded in 2000

Founder: Peoples' Friendship University of Russia named after Patrice Lumumba

Editor-in-Chief

Yury N. Razoumny — Dr. (Technical Sciences), Professor, Director of the Academy of Engineering, Head of the Department of Mechanics and Control Processes of the Academy of Engineering, RUDN University, Moscow, Russia

Associate Editor-in-Chief

Sergey V. Reznik — Dr. (Technical Sciences), Professor, Head of the Department SM-13 "Composite Materials for Aerospace", Special Machinery Faculty, Bauman Moscow State Technical University, Moscow, Russia

Assistant to the Editor-in-Chief

Svetlana V. Agasieva — Ph.D. (Technical Sciences), Associate Professor of the Department of Nanotechnology and Microsystem Engineering, Academy of Engineering, RUDN University, Moscow, Russia

Editorial Board

Brij Agrawal — Professor, Naval Postgraduate School, Monterey, USA

Oleg M. Alifanov — Academician of the Russian Academy of Sciences, Dr. (Technical Sciences), Professor, Moscow Aviation Institute (National Research University), Moscow, Russia

Fabio Celani — Professor, Sapienza University of Rome, Rome, Italia

Rock Jeng-Shing Chern — Professor, Ryerson University, Toronto, Canada

Roberto Furfaro — Professor, University of Arizona, Tucson, USA

Paolo Gasbarri — Professor, Sapienza University of Rome, Rome, Italia

Giancarlo Genta — Professor, Polytechnic University of Turin, Turin, Italia

Ioannis Zois Gitis — Professor, Aristotle University of Thessaloniki, Thessaloniki, Greece

Filippo Graziani — Full Professor, Sapienza University of Rome, Rome, Italia

Anna Guerman — Professor, University of Beira Interior, Covilhã, Portugal

Pini Gurfil — Full Professor, Israel Institute of Technology, Haifa, Israel

Moriba Jah — Associate Professor, University of Texas at Austin, Austin, USA

Vladimir T. Kalugin — Dr. (Technical Sciences), Professor, Bauman Moscow State Technical University, Moscow, Russia

Vladimir M. Kapustin — Dr. (Technical Sciences), Professor, National University of Oil and Gas "Gubkin University" (Gubkin University), Moscow, Russia

Junichiro Kawaguchi — Professor, Japan Aerospace Exploration Agency, Tokyo, Japan

Nikolay B. Kuznetsov — Professor, Geological Institute of the Russian Academy of Sciences, Moscow, Russia

Richard Linares — Professor, Massachusetts Institute of Technology, Cambridge, USA

Maxim M. Matyushin — Dr. (Technical Sciences), Mission Control Center (TSUP), Central Research Institute for Machine Building (TsNIMash), State Space Corporation "Roscosmos", Korolev, Russia

Andrey V. Medvedev — Dr. (Physical and Mathematical Sciences), corresponding member of Siberian Branch of the Russian Academy of Sciences, Institute of Solar-Terrestrial Physics of the Siberian Branch of the Russian Academy of Sciences, Irkutsk, Russia

Arun Misra — Professor, McGill University, Montreal, Canada

Seidu O. Mohammed — Professor, National Space Research and Development Agency, Abuja, Nigeria

Daniele Mortari — Professor, Texas A&M University, College Station, USA

Giovanni Palmerini — Professor, Sapienza University of Rome, Rome, Italia

Vyacheslav G. Petukhov — Dr. (Technical Sciences), corresponding member of the Russian Academy of Sciences, Moscow Aviation Institute (National Research University), Moscow, Russia

Yury S. Popkov — Academician of the Russian Academy of Sciences, Dr. (Technical Sciences), Professor, Institute for Systems Analysis, Federal Research Center "Computer Science and Control" of the Russian Academy of Sciences, Moscow, Russia

Harri A. Popov — Academician of the Russian Academy of Sciences, Dr. (Technical Sciences), Professor, Director of the Research Institute of Applied Mechanics and Electrodynamics, Moscow Aviation Institute (National Research University), Moscow, Russia

Antonio Prado — Professor, National Institute for Space Research, Sao Jose dos Campos, Brazil

Ivan Y. Redko — Dr. (Technical Sciences), Professor, Krzhizhanovsky Energy Institute, Moscow, Russia

David B. Spencer — Professor, Pennsylvania State University, University Park, USA

Renuganth Varatharajoo — Professor, University Putra Malaysia, Seri Kembangan, Malaysia

Massimiliano L. Vasile — Professor, University of Strathclyde, Glasgow, United Kingdom

Antonio Viviani — Professor, University of Campania "Luigi Vanvitelli", Naples, Italy

Tetsuo Yasaka — Professor Emeritus, Kyushu University, Fukuoka, Japan

RUDN JOURNAL OF ENGINEERING RESEARCH

Published by the Peoples' Friendship University of Russia named after Patrice Lumumba (RUDN University)

ISSN 2312-8143 (Print); ISSN 2312-8151 (Online)

Publication frequency: quarterly.

Journal homepage: <http://journals.rudn.ru/engineering-researches> (Open Access) 

Languages: Russian, English.

Indexed by Russian Index of Science Citation, DOAJ, Ulrich's Periodicals Directory, Cyberleninka, Google Scholar, WorldCat, Dimensions, ResearchBib, Lens, Research4Life, JournalTOCs, British Library, Bodleian Libraries (University of Oxford), Ghent University Library.

Aims and Scope

The RUDN Journal of Engineering Research — is a peer-reviewed international academic journal publishing research in the field of aviation and space technology, mechanical engineering. The journal is international in terms of the composition of the editorial board, authors and topics of publications. The journal publishes the results of original scientific research by Russian and foreign scientists.

The aims of the journal:

- assistance in the development of Russian and foreign engineering schools;
- promotion and implementation into practice of modern advanced technologies in these areas;
- scientific exchange and collaboration between scientists.

The journal is addressed to researchers, engineers, graduate students. Included in the List of the Leading Scientific Journals and Editions of the Highest Certification Committee of the Ministry of Education and Science of Russian Federation in which the basic results of PhD and Doctoral theses are to be published.

The journal website operates on the Portal of RUDN University scientific journals <http://journals.rudn.ru/engineering-researches> and contains full information about the journal, editorial policy and ethics, requirements for the preparation and publication of the articles, as well as full-text issues of the journal since 2008 (Open Access).

Editorial Board strictly adheres to the international standards of publication ethics of the COPE:

<http://publicationethics.org>

Copy Editor *I.L. Pankratova*

English Texts' Editor *A.S. Korzin, E.F. Shaleeva, N.A. Alekseeva*

Layout Designer *N.V. Markelova*

Address of the editorial board:

3 Ordzhonikidze St, Moscow, 115419, Russian Federation

Ph.: +7 (495) 955-07-16; e-mail: publishing@rudn.ru

Address of the editorial board of RUDN Journal of Engineering Research:

3 Ordzhonikidze St, Moscow, 115419, Russian Federation

Ph.: +7 (495) 955-07-92; e-mail: engj@rudn.ru

Printing run 500 copies. Open price.

Peoples' Friendship University of Russia named after Patrice Lumumba

6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation

Printed at RUDN Publishing House:

3 Ordzhonikidze St, Moscow, 115419, Russian Federation

Ph.: +7 (495) 955-08-61; e-mail: publishing@rudn.ru

© Peoples' Friendship University of Russia named after Patrice Lumumba, 2025

СОДЕРЖАНИЕ

Пичугин С.Б. Этапы структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами	211
Старков А.В., Морозов А.А. Методология управления потоками целевой информации в космической системе ДЗЗ. Часть 4. Сетевые орбитальные группировки	227
Vorontsov V.A., Quispe Mendoza M.V. Aerial Platforms for Exploration Under Extreme Conditions in the Venus Atmosphere (Воздушные платформы для исследований в экстремальных условиях в атмосфере Венеры)	245
Saltykova O.A., Saushkin V.D. Regression Neural Networks Advantage over Classical Regression Analysis (Преимущество регрессионных нейронных сетей перед классическим регрессионным анализом).....	258
Лобанов В.К., Кондрашина М.С., Гаджиев Ш.М., Сокибеков М.Ш. Генерация реалистичных изображений нефтегазовой инфраструктуры на космических снимках с использованием диффузионных моделей	266
Fahmi A.T.W.K., Reza Kashyzadeh K., Ghorbani S., Kupreev S.A., Samusenko O.E. Comparative Performance of Machine Learning Classifiers in Detecting Vibration Anomalies in Industrial Power Systems (Сравнительная эффективность классификаторов машинного обучения при обнаружении аномалий вибрации в промышленных энергосистемах)	273
Захаров Д.С., Рогачев А.Ф. Статистический анализ функционирования модифицированных генетических алгоритмов для автоматизированного составления расписания многоуровневого вуза	288
Захарова А.В., Вишнякова А.Ю., Детков А.А. Сравнение моделей и методов классификации текста.....	298
Uwingabiye F., Kimenyi T., Kimenyi A., Kruglova L.V. Prediction of Breast Cancer Using Machine Learning (Прогнозирование рака груди с помощью машинного обучения)	310
Глушкова Ю.О., Мнацаканян В.У. Развитие профессиональных компетенций специалистов в сфере автомобильного транспорта как фактор повышения эффективности транспортно-логистических услуг	323

CONTENTS

Pichugin S.B. Stages of Structural and Parametric Synthesis of Low Earth Orbit Communication Systems with Broadband Inter-Satellite Links	211
Starkov A.V., Morozov A.A. Methodology for Managing Target Information Flows in the Remote Sensing Space System. Part 4. Network Orbital Groupings	227
Vorontsov V.A., Quispe Mendoza M.V. Aerial Platforms for Exploration Under Extreme Conditions in the Venus Atmosphere	245
Saltykova O.A., Saushkin V.D. Regression Neural Networks Advantage over Classical Regression Analysis	258
Lobanov V.K., Kondrashina M.S., Gadzhiev Sh.M., Sokibekov M.Sh. Generating Realistic Images of Oil and Gas Infrastructure in Satellite Imagery Using Diffusion Models	266
Fahmi A.T.W.K., Reza Kashyzadeh K., Ghorbani S., Kupreev S.A., Samusenko O.E. Comparative Performance of Machine Learning Classifiers in Detecting Vibration Anomalies in Industrial Power Systems	273
Zakharov D.S., Rogachev A.F. Statistical Analysis of the Performance of Modified Genetic Algorithms for Automated Compilation of a Multilevel University Scheduling	288
Zakharova A.V., Vishnyakova A.Yu., Detkov A.A. Comparison of Text Classification Models and Methods	298
Uwingabiye F., Kimenyi T., Kimenyi A., Kruglova L.V. Prediction of Breast Cancer Using Machine Learning ...	310
Glushkova Yu.O., Mnatsakanyan V.U. Development of Professional Competencies of Specialists in the Field of Motor Transport as a Factor of Increasing the Efficiency of Transport and Logistics Services ...	323



DOI: 10.22363/2312-8143-2025-26-3-211-226

EDN: VTMTST

Научная статья / Research article

Этапы структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами

С.Б. Пичугин^{ID}

ПАО «РКК „Энергия“», Королёв, Российская Федерация

✉ sergey.pichugin@rsce.ru

История статьи

Поступила в редакцию: 28 марта 2025 г.

Доработана: 12 мая 2025 г.

Принята к публикации: 20 мая 2025 г.

Заявление о конфликте интересов

Автор заявляет об отсутствии конфликта интересов.

Аннотация. Рассмотрены вопросы научного обоснования структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами и маршрутизацией данных на борту спутника, принципы и этапы, положенные в основу маршрутизации данных на борту спутников, и построения надежных и широкополосных межспутниковых трактов. Цель исследования — конкретизация структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами. Объект исследования — группировка спутников на низких орбитах с маршрутизацией данных на борту. Предметом исследования является процесс синтеза структуры соответствующей низкоорбитальной системы. Методология исследования включает математический аппарат систем массового обслуживания, применяемый как часть инструментария системного анализа. Научная значимость исследования заключается в разработке принципов и методов, позволяющих проводить структурно-параметрический анализ и разработку перспективных спутниковых систем связи, а также моделирования поведения низкоорбитальных систем связи с широкополосными межспутниковыми трактами и оценку их результативности. Практическая значимость исследования состоит в обеспечении формирования перечня работ по созданию отечественных группировок спутников, обеспечивающих абонентскую персональную связь с передачей данных от абонента к абоненту без промежуточного приземления сигнала.

Ключевые слова: синтез космической системы, низкоорбитальная система связи, маршрутизация данных на борту спутника, межспутниковые тракты

Для цитирования

Пичугин С.Б. Этапы структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 211–226. <http://doi.org/10.22363/2312-8143-2025-26-3-211-226>



Stages of Structural and Parametric Synthesis of Low Earth Orbit Communication Systems with Broadband Inter-Satellite Links

Sergey B. Pichugin 

Rocket and Space Corp “Energia” named by S.P. Korolev, RSCE, Moscow, Russian Federation

✉ sergey.pichugin@rsce.ru

Article history

Received: March 28, 2025

Revised: May 12, 2025

Accepted: May 20, 2025

Conflicts of interest

The author declares that there is no conflict of interest.

Abstract. The paper discusses the scientific rationale for the structural and parametric synthesis of low Earth orbit communication systems (LEOCSs) with broadband inter-satellite links (ISLs) and on-board data routing, principles and stages underlying data routing on board satellites and the construction of reliable and broadband inter-satellite links. The aim of the study is to specify a structural and parametric synthesis of low-orbital communication systems with broadband inter-satellite links. The object of the study is the constellation of satellites in low-altitude orbits with on-board data routing. The subject of study is the process of synthesis of the structure of the corresponding low-orbital system. The methodology of the study includes mathematical apparatus of queuing systems, used as part of the system analysis toolkit. The scientific significance of the research lies in the development of principles and methods that enable structural and parametric analysis and the development of promising satellite communication systems. Additionally, the research involves the modeling of the behavior of low-orbit communication systems with broadband inter-satellite links and the assessment of their effectiveness. The practical significance of the research is to provide a list of tasks for the creation of domestic satellite constellations that provide personal subscriber communications with data transmission from subscriber to subscriber without intermediate signal landing.

Keywords: space system synthesis, low orbit communications system, data routing on board of a satellite, intersatellite links

For citation

Pichugin SB. Stages of structural and parametric synthesis of low Earth orbit communication systems with broadband inter-satellite links. *RUDN Journal of Engineering Research*. 2025;26(3):211–226. (In Russ.) <http://doi.org/10.22363/2312-8143-2025-26-3-211-226>

Введение

На текущий момент существенно возрос интерес к практической реализации проектов систем связи со спутниками на низких околоземных орбитах. Интерес обусловлен, с одной стороны, тем, что абоненты космических систем связи требуют обеспечить им тот же уровень сервиса, который обеспечен им в наземных сотовых и проводных системах связи, при этом спутниковые системы со спутниками на

высокоэллиптических и геостационарной орбитах такой сервис зачастую обеспечить не в состоянии¹.

С другой стороны, такой интерес обусловлен тем, что развитие производства, науки и среды управления в некоторых странах, в частности в США, сделало возможным такой сервис обеспечить [1]. Примером являются реализованные в США проекты низкоорбитальных систем Иридиум и Старлинк [2; 3], которые в 2025 г. приближаются к окупаемости или

¹ Дятлов А.П. Системы спутниковой связи с подвижными объектами : учебное пособие. Таганрог : Изд-во Таганрогского государственного радиотехнического университета, 2004. 92 с.; Катунин Г.П., Мамчев Г.В., Попантонопуло В.Н., Шувалов В.П. Телекоммуникационные системы и сети. Том 2. Радиосвязь, радиовещание, телевидение : учебное пособие. Москва : Горячая Линия — Телеком, 2004. 672 с. ISBN 5-93517-109-0

вышли на окупаемость². В то же время становится очевидным, что расширение рынка и спектра услуг космической связи тормозит ряд ключевых проблем, не позволяющих реализовать тот же уровень сервиса, что и в наземных системах. В перечне важнейших проблем такого ранга выделяются две [4–6]: маршрутизация данных на борту спутников, составляющих орбитальную группировку и построение надежных и широкополосных межспутниковых трактов (МСТ) в низкоорбитальных системах связи (НОСС). Таким образом, маршрутизация данных на борту спутника и передача данных по широкополосным МСТ являются ключевыми факторами структурно-параметрического синтеза НОСС, обеспечивающими соответствие космической связи возросшим запросам абонентов.

1. Методы бортовой маршрутизации и обеспечения работы межспутниковых трактов

В разработке научно-технических основ маршрутизации данных на борту спутника и передачи данных по широкополосным МСТ задействован ряд предприятий космической промышленности России. В частности, в ПАО «РКК «Энергия» разработаны и запатентованы [7–11] решения, позволяющие обеспечить широкополосную связь абонентов через группы спутников, без промежуточного приземления сообщения, с учетом особенностей НОСС. Например, метод с чтением части заголовка, когда часть предыдущего заголовка запоминают, сравнивают с аналогичной частью текущего, при совпадении отправляют далее либо прочитывают полностью перед дальнейшей отправкой [7], а также метод, использующий для маршрутизации головной бит, когда «0» или «1» отправляет последовательность данных в одном из двух направлений и далее не пере-

дается («срезается») и на следующем каскаде данные маршрутизируются следующим головным битом [8]. При этом выбор направления ретрансляции данных осуществляют исходя из информации о координатах ближайших соседей, своего местоположения и координатах получателя. Координатами являются номер зоны, в которой находится спутник или его сосед. Если сосед вышел из строя (неисправность, перегрузка и т.д.) и не передал свои координаты за текущий период обмена, то информация о его координатах на соседних спутниках стирается. При восстановлении работоспособности она может быть возобновлена. Пример нумерации зон приведен на рис. 1.

Взаимодействие спутников в НОСС показано на рис. 2.

Для реализации технических решений, связанных с маршрутизацией данных на борту спутника и передачей данных по широкополосным МСТ, на базе методов системного анализа был сформулирован ряд принципов.

Принцип 1: абонентские тракты обеспечивают связь через атмосферу Земли и реализованы в радиодиапазоне от 0,3 до 4 ГГц.

Принцип 2: широкополосные МСТ реализуют на базе устройств лазерной связи (диапазон выше 300 ГГц) либо на базе радиоаппаратуры сантиметрового или миллиметрового диапазонов (диапазон от 18 до 60 ГГц), при этом устанавливая связь с ближайшими спутниками-соседями, спутники ищут друг друга, сканируя лучом широкую область и, найдя друг друга, сужают ее.

Принцип 3: позиции лазерного или радиолуча нумеруют на стороне спутника-отправителя, а на стороне спутника-соседа берут пеленг на принятый луч и в служебном сообщении в виде кода поправки наведения, информируют о пеленге и номере позиции спутник-отправитель. Это ускоряет поиск и повышает надежность сопровождения спутников-соседей.

² Отчет о доходах Iridium Communications Inc. 22.04.2025. URL: <https://ru.tradingview.com/symbols/NASDAQ-IRDM/financials-income-statement/> (дата обращения: 30.05.2025); *Потанов И.В.* Стало известно о резком росте доходов от Starlink (URL: <https://lenta.ru/news/2025/02/05/stalo-izvestno-o-rezkom-roste-dohodov-ot-starlink/> (дата обращения: 30.05.2025).




Рис. 1. Пример нумерации зон в НОСС

Источник: выполнено С.Б. Пичугиным

Figure 1. Sample zone numbering in LEOCS

Source: by S.B. Pichugin




Рис. 2. Взаимодействие спутников в НОСС:

1 — орбитальная плоскость; 2 — спутник, 3 — спутник — сосед; 4 — МСТ

Источник: выполнено С.Б. Пичугиным

Figure 2. Interaction of satellites in LEOCS:

1 — the orbital plane; 2 — satellite, 3 — satellite neighbor; 4 — MCT

Source: by S. B. Pichugin

Принцип 4: в районах орбитальных полюсов, там, где угловые скорости взаимного перемещения спутников на соседних орбитах возрастают, применяют перехватывающее сопровождение соседнего спутника набором бортовых антенн спутника антенн, чьи зоны обслуживания частично перекрываются.

Принцип 5: идентификация абонентских зон, обслуживаемых спутниками, осуществляется зонированием поверхности земли по числу спутников, а данные местоположения спутника и абонентов включаются в маршрутную информацию, необходимую для доставки сообщений от абонентов-отправителей к абонентам-получателям.

Реализация приведенных принципов в рамках технических решений, закладываемых в создаваемые спутники орбитальной группировки и в наземный сегмент НОСС, позволяет существенно улучшить характеристики предоставляемых сервисов космической связи и повышает ее конкурентоспособность в сравнении с наземной связью [6; 12; 16]. Для объективной оценки соответствующих характеристик технических решений, реализуемых в НОСС, и научного обоснования выбора соответствующих методов маршрутизации и межспутниковой связи в НОСС необходим соответствующий математический аппарат.

2. Научное обоснование выбора метода бортовой маршрутизации и обеспечения работы межспутниковых трактов

При выборе метода бортовой маршрутизации и обеспечения работы межспутниковых трактов и соответствующих технических решений был разработан и применялся математический аппарат на базе методов теории массового обслуживания⁴, который позволил исследовать, дать научное описание и обосновать для различных условий функционирования НОСС, в том числе штатных и нештатных, соответствующий выбор методов и средств.

Моделирование дало возможность комплексно исследовать спутник с маршрутизацией сообщений на борту и двумя типами трактов — абонентским, направленным в сторону Земли и обеспечивающим связь в диапазоне от 0,3 до 4 ГГц и межспутниковым трактом оптического диапазона от 300 ГГц до 700 ТГц.

Чтобы оценить процессы, происходящие в бортовой аппаратуре спутника с широкополосными межспутниковыми трактами и маршрутизацией данных на борту, была предложена двухосевая двухфазная модель его функционирования, базирующаяся на математическом аппарате систем массового обслуживания, приведенная на рис. 3.

Модель включала четыре обслуживающих прибора на двух осях — по два прибора на каждую ось, именуемых головным и замыкающим.

В соответствии с предложенной моделью на входы головных приборов каждой оси поступает простейший поток заявок интенсивности λ_0 (на головной прибор первой оси) и λ_2 (на головной прибор второй оси). Время обслуживания заявок на указанных головных приборах распределено по экспоненциальному закону с параметром μ_{01} или μ_{21} , соответственно. После обслуживания на головном приборе первой оси заявка с головного прибора с вероятностью ε_0 поступает на замыкающий прибор этой же оси и с вероятностью $(1 - \varepsilon_0)$ поступает на замыкающий прибор другой оси. Аналогично, после обслуживания на головном приборе второй оси, заявка с головного прибора с вероятностью ε_2 поступает на замыкающий прибор этой же оси и, с вероятностью $(1 - \varepsilon_2)$, поступает на замыкающий прибор первой оси.

Исследуемая система массового обслуживания может находиться в следующих 16 состояниях:

- S_{0000} — все приборы свободны;
- S_{0001} — замыкающий прибор второй оси занят, остальные приборы свободны;
- S_{0010} — головной прибор второй оси занят, остальные приборы свободны;

⁴ Назаров А.А., Терпугов А.Ф. Теория массового обслуживания : учебное пособие. Томск : НТЛ, 2004. 228 с. ISBN 5-89503-233-8 EDN: QJOKAZ

S_{0011} — головной и замыкающий прибор второй оси занят, приборы первой оси свободны;

S_{0100} — замыкающий прибор первой оси занят, остальные приборы свободны;

S_{0101} — замыкающие приборы первой и второй оси заняты, остальные приборы свободны;

S_{0110} — замыкающий прибор первой оси и головной прибор второй оси заняты, остальные приборы свободны;

S_{0111} — головной прибор первой оси свободен, остальные приборы заняты;

S_{1000} — головной прибор первой оси занят, остальные приборы свободны;

S_{1001} — головной прибор первой оси и замыкающий прибор второй оси заняты, остальные приборы свободны;

S_{1010} — головные приборы первой и второй оси заняты, остальные приборы свободны;

S_{1011} — замыкающий прибор первой оси свободен, остальные приборы заняты;

S_{1100} — головной и замыкающий приборы первой оси заняты, приборы второй оси свободны;

S_{1101} — головной прибор второй оси свободен, остальные приборы заняты;

S_{1110} — замыкающий прибор второй оси свободен, остальные приборы заняты;

S_{1111} — все приборы заняты.




Рис. 3. Двухосевая двухфазная модель функционирования спутника

Источник: выполнено С.Б. Пичугиным

Figure 3. Two — axis and two — phased model of operation of the satellite

Source: by S.B. Pichugin

Соответственно $p_{ijkl}(t)$ — вероятность нахождения системы массового обслуживания в состоянии i, j, k, l , где $i = 0$ или $1, j = 0$ или $1, k = 0$ или 1 и $l = 0$ или 1 .

Если при поступлении заявки состояние системы «все приборы свободны», то заявка считается успешно обслуженной. Если свободны головной и замыкающий приборы одной

оси, то заявка считается обслуженной с вероятностью ϵ_0 или ϵ_2 соответственно, дополненной вероятностью $(1 - \epsilon_2)$ или $(1 - \epsilon_0)$ противоположной оси, что означает, что часть заявок могут перемещаться между осями. Если свободны головной прибор одной и замыкающий прибор противоположной оси, то заявка считается обслуженной с вероятностью $(1 - \epsilon_0)$ или

$(1 - \varepsilon_2)$ соответственно. Если в комбинации состояний приборов системы оба головных прибора заняты, поступившая заявка теряется.

На базе предложенной модели была получена система дифференциальных уравнений Колмогорова. Процесс получения указанных уравнений показан на примере состояния S_{0000} .

На первом этапе для состояния S_{0000} был построен граф переходов, приведенный на рис. 4, где учтены переходы из этого состояния во все возможные состояния системы (их всего 16, что соответствует 24, где 4 — число приборов в модели).

Далее исследовалось изменение состояний системы на бесконечно малом интервале Δt . Имеем в виду, что интервал Δt таков, что для

простейшего потока в котором интервалы между поступлениями отдельных заявок подчиняются закону с плотностью распределения $p(t) = \lambda e^{-\lambda t}$, вероятность поступления очередной заявки интервале Δt приближенно равна $\lambda \Delta t$.

Кроме того, такой простейший поток характеризуется тем, что суммарный поток заявок, полученный объединением конечного числа потоков с экспоненциальными законами распределения с различными интенсивностями, является экспоненциальным потоком с интенсивностью, равной сумме их интенсивностей [13–15].

Исходя из указанных соображений, вероятность того, что состояние S_{0000} в момент времени $(t + \Delta t)$, записывается, в соответствии с графом на рис. 4, в виде выражения (1).




Рис. 4. Граф переходов из состояния S_{0000} в прочие состояния системы

Источник: выполнено С.Б. Пичугины

Figure 4. Flow graph from the S_{0000} state to all other states of the queuing system

Source: by S.B. Pichugin

Уравнение (1) дублировалось для всех шестнадцати состояний. После этого все полученные уравнения, в результате преобразований, сводились к виду, характерному для стационарного режима, такому, когда все переходные процессы в модели были завершены, а малые

второго и выше порядков исключены из рассмотрения. Для стационарного режима функционирования модели НОСС дифференциальные уравнения Колмогорова были сведены в систему из 16 линейных уравнений и дополнены уравнением полной вероятности (см. табл.).

$$\begin{aligned}
 p_{0000}(t + \Delta t) = & p_{0000}(t) - p_{0000}(t) * (\lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2) \Delta t - p_{0000}(t) \lambda_2 \Delta t - p_{0000}(t) [\lambda_2 + \lambda_2 \varepsilon_2 + \\
 & + \lambda_2(1 - \varepsilon_2)] \Delta t - p_{0000}(t) [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)] \Delta t - p_{0000}(t) [\lambda_0 \varepsilon_0 + \lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2 + \lambda_2(1 - \varepsilon_2)] * \Delta t - \\
 & - p_{0000}(t) * [\lambda_2 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)] \Delta t - p_{0000}(t) * [\lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2 + \lambda_2 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)] * \Delta t - \\
 & - p_{0000}(t) * \lambda_0 * \Delta t - p_{0000}(t) [\lambda_0 + \lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2] * \Delta t - p_{0000}(t) [\lambda_0 + \lambda_2] * \Delta t - p_{0000}(t) [\lambda_0 + \\
 & + \lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2 + \lambda_2 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)] * \Delta t - p_{0000}(t) [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)] * \Delta t - \\
 & - p_{0000}(t) [\lambda_0 + \lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)] * \Delta t - p_{0000}(t) [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2 + \lambda_2(1 - \varepsilon_2)] * \Delta t - \\
 & - p_{0000}(t) [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \lambda_0(1 - \varepsilon_0) + \lambda_2 \varepsilon_2] * \Delta t + p_{0001}(t) \mu_{22} * \Delta t + p_{0010}(t) \mu_{21} * \Delta t + \\
 & + p_{0011}(t) * (\mu_{21} + \mu_{22}) * \Delta t + p_{0100}(t) \mu_{02} * \Delta t + p_{0101}(t) * (\mu_{02} + \mu_{22}) * \Delta t + p_{0110}(t) * (\mu_{02} + \mu_{21}) * \Delta t + \\
 & + p_{0111}(t) * (\mu_{02} + \mu_{21} + \mu_{22}) * \Delta t + p_{1000}(t) \mu_{01} * \Delta t + p_{1001}(t) * (\mu_{01} + \mu_{22}) * \Delta t + p_{1010}(t) * (\mu_{01} + \mu_{21}) * \Delta t + \\
 & + p_{1011}(t) * (\mu_{01} + \mu_{21} + \mu_{22}) * \Delta t + p_{1100}(t) * (\mu_{01} + \mu_{02}) * \Delta t + p_{1101}(t) * (\mu_{01} + \mu_{02} + \mu_{22}) * \Delta t + p_{1110}(t) * \\
 & * (\mu_{01} + \mu_{02} + \mu_{21}) * \Delta t + p_{1111}(t) * (\mu_{01} + \mu_{02} + \mu_{21} + \mu_{22}) * \Delta t
 \end{aligned} \quad (1)$$

**Система линейных уравнений для стационарного режима функционирования НОСС,
дополненная уравнением полной вероятности /**

Set of linear equations for stationary mode of operation of LEOCS, supplemented by full probability equation

Состояние / State	Уравнение Колмогорова / Kolmogorov equation
S_{0000}	$ \begin{aligned} & - 8[\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_0(1 - \varepsilon_0) + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_2(1 - \varepsilon_2)] p_{0000}(t) + \mu_{22} p_{0001}(t) + \mu_{21} p_{0010}(t) + \\ & + (\mu_{21} + \mu_{22}) p_{0011}(t) + \mu_{02} p_{0100}(t) + (\mu_{02} + \mu_{22}) p_{0101}(t) + (\mu_{02} + \mu_{21}) p_{0110}(t) + \\ & + (\mu_{02} + \mu_{21} + \mu_{22}) p_{0111}(t) + \mu_{01} p_{1000}(t) + (\mu_{01} + \mu_{22}) p_{1001}(t) + (\mu_{01} + \mu_{21}) p_{1010}(t) + \\ & + (\mu_{01} + \mu_{21} + \mu_{22}) p_{1011}(t) + (\mu_{01} + \mu_{02}) p_{1100}(t) + (\mu_{01} + \mu_{02} + \mu_{22}) p_{1101}(t) + \\ & + (\mu_{01} + \mu_{02} + \mu_{21}) p_{1110}(t) + (\mu_{01} + \mu_{02} + \mu_{21} + \mu_{22}) p_{1111}(t) = 0 \end{aligned} $
S_{0001}	$ \begin{aligned} & [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{0000}(t) - 8[(\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22} + \lambda_0 + \lambda_2)] p_{0001}(t) + \\ & + [\mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{0010}(t) + \mu_{21} p_{0011}(t) + [\mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{0100}(t) + \\ & + \mu_{02} p_{0101}(t) + [\mu_{02} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{0110}(t) + [\mu_{02} + \mu_{21}] p_{0111}(t) + \\ & + [\mu_{01} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{1000}(t) + \mu_{01} p_{1001}(t) + [\mu_{01} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{1010}(t) + \\ & + [\mu_{01} + \mu_{21}] p_{1011}(t) + [\mu_{01} + \mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{1100}(t) + [\mu_{01} + \mu_{02}] p_{1101}(t) + \\ & + [\mu_{01} + \mu_{02} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)] p_{1110}(t) + [\mu_{01} + \mu_{02} + \mu_{21}] p_{1111}(t) = 0 \end{aligned} $
S_{0010}	$ \begin{aligned} & \lambda_2 p_{0000}(t) + [\lambda_2 + \mu_{22}] p_{0001}(t) - 8[\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \lambda_0] p_{0010}(t) + \\ & + \mu_{22} p_{0011}(t) + [\mu_{02} + \lambda_2] p_{0100}(t) + [\mu_{02} + \lambda_2 + \mu_{22}] p_{0101}(t) + \mu_{02} p_{0110}(t) + \\ & + [\mu_{02} + \mu_{22}] p_{0111}(t) + [\mu_{01} + \lambda_2] p_{1000}(t) + [\mu_{01} + \lambda_2 + \mu_{22}] p_{1001}(t) + \mu_{01} p_{1010}(t) + \\ & + [\mu_{01} + \mu_{22}] p_{1011}(t) + [\mu_{01} + \mu_{02} + \lambda_2] p_{1100}(t) + [\mu_{01} + \mu_{02} + \lambda_2 + \mu_{22}] p_{1101}(t) + \\ & + [\mu_{01} + \mu_{02}] p_{1110}(t) + [\mu_{01} + \mu_{02} + \mu_{22}] p_{1111}(t) = 0 \end{aligned} $

Продолжение табл. / Continuation of the Table

Состояние / State	Уравнение Колмогорова / Kolmogorov equation
S_{0011}	$ \begin{aligned} & [\lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0000}(t) + \lambda_2 p_{0001}(t) + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0010}(t) + \\ & - 8[\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_0 + \mu_{21} + \mu_{22}]p_{0011}(t) + [\mu_{02} + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0100}(t) + \\ & + (\mu_{02} + \lambda_2)p_{0101}(t) + [\mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0110}(t) + \mu_{02}p_{0111}(t) + \\ & + [\mu_{01} + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1000}(t) + [\mu_{01} + \lambda_2]p_{1001}(t) + [\mu_{01} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1010}(t) + \\ & + \mu_{01}p_{1011}(t) + [\mu_{01} + \mu_{02} + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1100}(t) + [\mu_{01} + \mu_{02} + \lambda_2]p_{1101}(t) + \\ & + [\mu_{01} + \mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1110}(t) + [\mu_{01} + \mu_{02}]p_{1111}(t) = 0 \end{aligned} $
S_{0100}	$ \begin{aligned} & [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0000}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{0001}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{0010}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \mu_{22}]p_{0011}(t) - \\ & - 8[\mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \lambda_2 + \lambda_0]p_{0100}(t) + \mu_{22}p_{0101}(t) + \mu_{21}p_{0110}(t) + \\ & + [\mu_{21} + \mu_{22}]p_{0111}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1000}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{1001}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{1010}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \mu_{22}]p_{1011}(t) + \mu_{01}p_{1100}(t) + [\mu_{01} + \mu_{22}]p_{1101}(t) + \\ & + [\mu_{01} + \mu_{21}]p_{1110}(t) + [\mu_{01} + \mu_{21} + \mu_{22}]p_{1111}(t) = 0 \end{aligned} $
S_{0101}	$ \begin{aligned} & [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0000}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0001}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0010}(t) + (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21})p_{0011}(t) + \\ & + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0100}(t) - 8[\mu_{02} + \mu_{22} + \lambda_2 + \lambda_0]p_{0101}(t) + [\mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0110}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0111}(t) + \mu_{21}p_{1000}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1001}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1010}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{1011}(t) + [\mu_{01} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1100}(t) + \mu_{01}p_{1101}(t) + \\ & + [\mu_{01} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1110}(t) + [\mu_{01} + \mu_{21}]p_{1111}(t) = 0 \end{aligned} $
S_{0110}	$ \begin{aligned} & (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2)p_{0000}(t) + (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \mu_{22})p_{0001}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0010}(t) + (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22})p_{0011}(t) + \\ & + \lambda_2 p_{0100}(t) + (\lambda_2 + \mu_{22})p_{0101}(t) - 8[\mu_{02} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \lambda_0]p_{0110}(t) + \\ & + \mu_{22}p_{0111}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2]p_{1000}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \\ & + \lambda_2 + \mu_{22}]p_{1001}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1010}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{1011}(t) \\ & + [\mu_{01} + \lambda_0]p_{1100}(t) + [\mu_{01} + \lambda_2 + \mu_{22}]p_{1101}(t) + \mu_{01}p_{1110}(t) + [\mu_{01} + \mu_{22}]p_{1111}(t) = 0 \end{aligned} $
S_{0111}	$ \begin{aligned} & [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{0000}(\tau) + (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2)\pi_{0001}(\tau) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{0010}(\tau) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]\pi_{0011}(\tau) + \\ & + [\lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{0100}(\tau) + \lambda_2 \pi_{0101}(\tau) + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{0110}(\tau) - \\ & - 8[(\lambda_0 + \mu_{02} + \mu_{21} + \mu_{22})]\pi_{0111}(\tau) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{1000}(\tau) + \\ & + (\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2)\pi_{1001}(\tau) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{1010}(\tau) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]\pi_{1011}(\tau) + [\mu_{01} + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{1100}(\tau) + [\mu_{01} + \lambda_2]\pi_{1101}(\tau) + \\ & + [\mu_{01} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]\pi_{1110}(\tau) + \mu_{01}\pi_{1111}(\tau) = 0 \end{aligned} $
S_{1000}	$ \begin{aligned} & [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0000}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{0001}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{0010}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \mu_{22}]p_{0011}(t) - 8[\mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \lambda_2 + \lambda_0]p_{0100}(t) + \\ & + \mu_{22}p_{0101}(t) + \mu_{21}p_{0110}(t) + [\mu_{21} + \mu_{22}]p_{0111}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1000}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{1001}(t) + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{1010}(t) + \\ & + [\mu_{01} + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \mu_{22}]p_{1011}(t) + \mu_{01}p_{1100}(t) + [\mu_{01} + \mu_{22}]p_{1101}(t) + \\ & + [\mu_{01} + \mu_{21}]p_{1110}(t) + [\mu_{01} + \mu_{21} + \mu_{22}]p_{1111}(t) = 0 \end{aligned} $

Продолжение табл. / Continuation of the Table

Состояние / State	Уравнение Колмогорова / Kolmogorov equation
S_{1001}	$ \begin{aligned} & [\lambda_0 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0000}(t) + \lambda_0 p_{0001}(t) + [\lambda_0 + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0010}(t) + \\ & + [\lambda_0 + \mu_{21}]p_{0011}(t) + [\lambda_0 + \mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0100}(t) + [\lambda_0 + \mu_{02}]p_{0101}(t) + \\ & + [\lambda_0 + \mu_{02} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0110}(t) + [\lambda_0 + \mu_{02} + \mu_{21}]p_{0111}(t) + \\ & + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1000}(t) - 8[\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \mu_{01} + \mu_{21}]p_{1001}(t) + \\ & + [\mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1010}(t) + \mu_{21}p_{1011}(t) + [\mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1100}(t) + \\ & + \mu_{02}p_{1101}(t) + [\mu_{02} + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1110}(t) + [\mu_{02} + \mu_{21}]p_{1111}(t) = 0 \end{aligned} $
S_{1010}	$ \begin{aligned} & [\lambda_0 + \lambda_2]p_{0000}(t) + [\lambda_0 + \lambda_2 + \mu_{22}]p_{0001}(t) + \lambda_0 p_{0010}(t) + [\lambda_0 + \mu_{22}]p_{0011}(t) + [\lambda_0 + \mu_{02} + \lambda_2]p_{0100}(t) + \\ & + [\lambda_0 + \mu_{02} + \lambda_2 + \mu_{22}]p_{0101}(t) + [\lambda_0 + \mu_{02}]p_{0110}(t) + [\lambda_0 + \mu_{02} + \mu_{22}]p_{0111}(t) + \lambda_2 p_{1000}(t) + \\ & + [\lambda_2 + \mu_{22}]p_{1001}(t) - 8[\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \mu_{01} + \mu_{21}]p_{1010}(t) + \mu_{22}p_{1011}(t) + \\ & + [\mu_{02} + \lambda_2]p_{1100}(t) + [\mu_{02} + \lambda_2 + \mu_{22}]p_{1101}(t) + \mu_{02}p_{1110}(t) + [\mu_{02} + \mu_{22}]p_{1111}(t) = 0 \end{aligned} $
S_{1011}	$ \begin{aligned} & [\lambda_0 + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0000}(t) + [\lambda_0 + \lambda_2]p_{0001}(t) + [\lambda_0 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0010}(t) + \\ & + \lambda_0 p_{0011}(t) + [\lambda_0 + \mu_{02} + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0100}(t) + [\lambda_0 + \mu_{02} + \lambda_2]p_{0101}(t) + \\ & + [\lambda_0 + \mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0110}(t) + [\lambda_0 + \mu_{02}]p_{0111}(t) + [\lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1000}(t) + \\ & + \lambda_2 p_{1001}(t) + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1010}(t) - 8[\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{01} + \mu_{21} + \mu_{22}]p_{1011}(t) + \\ & + [\mu_{02} + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1100}(t) + [\mu_{02} + \lambda_2]p_{1101}(t) + [\mu_{02} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1110}(t) + \\ & + \mu_{02}p_{1111}(t) = 0 \end{aligned} $
S_{1100}	$ \begin{aligned} & [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0000}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{0001}(t) + \\ & + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{0010}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \mu_{22}]p_{0011}(t) + \\ & + \lambda_0 p_{0100}(t) + [\lambda_0 + \mu_{22}]p_{0101}(t) + [\lambda_0 + \mu_{21}]p_{0110}(t) + [\lambda_0 + \mu_{21} + \mu_{22}]p_{0111}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1000}(t) + (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22})p_{1001}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{1010}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \mu_{22}]p_{1011}(t) - 8[\mu_{01} + \mu_{02} + (\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)) + \lambda_2]p_{1100}(t) + \\ & + \mu_{22}p_{1101}(t) + \mu_{21}p_{1110}(t) + [\mu_{21} + \mu_{22}]p_{1111}(t) = 0 \end{aligned} $
S_{1101}	$ \begin{aligned} & [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0000}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0001}(t) + \\ & + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0010}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{0011}(t) + \\ & + [\lambda_0 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0100}(t) + \lambda_0 p_{0101}(t) + [\lambda_0 + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0110}(t) + \\ & + [\lambda_0 + \mu_{21}]p_{0111}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1000}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1001}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1010}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{21}]p_{1011}(t) + \\ & + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1100}(t) - 8[\lambda_2 + \mu_{22} + \mu_{01} + \mu_{02}]p_{1101}(t) + [\mu_{21} + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1110}(t) + \\ & + \mu_{21}p_{1111}(t) = 0 \end{aligned} $
S_{1110}	$ \begin{aligned} & [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2]p_{0000}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \mu_{22}]p_{0001}(t) + \\ & + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0010}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{0011}(t) + [\lambda_0 + \lambda_2]p_{0100}(t) + \\ & + [\lambda_0 + \lambda_2 + \mu_{22}]p_{0101}(t) + \lambda_0 p_{0110}(t) + [\lambda_0 + \mu_{22}]p_{0111}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2]p_{1000}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \mu_{22}]p_{1001}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1010}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \mu_{22}]p_{1011}(t) + \lambda_2 p_{1100}(t) + (\lambda_2 + \mu_{22})p_{1101}(t) - 8[\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0) + \\ & + \mu_{01} + \mu_{02} + \mu_{21}]p_{1110}(t) + \mu_{22}p_{1111}(t) = 0 \end{aligned} $

Окончание табл. / Ending of the Table

Состояние / State	Уравнение Колмогорова / Kolmogorov equation
S_{1111}	$ \begin{aligned} & [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0000}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2]p_{0001}(t) + \\ & + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0010}(t) + [\lambda_0 + \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{0011}(t) + \\ & + [\lambda_0 + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0100}(t) + [\lambda_0 + \lambda_2]p_{0101}(t) + [\lambda_0 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{0110}(t) + \\ & + \lambda_0 p_{0111}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1000}(t) + (\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2)p_{1001}(t) + \\ & + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1010}(t) + [\lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2)]p_{1011}(t) + \\ & + [\lambda_2 + \lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1100}(t) + \lambda_2 p_{1101}(t) + [\lambda_2 \varepsilon_2 + \lambda_0(1 - \varepsilon_0)]p_{1110}(t) - \\ & - 8[\mu_{01} + \mu_{02} + \mu_{21} + \mu_{22}]p_{1111}(t) = 0 \end{aligned} $

Источник: выполнено С.Б. Пичугиным / Source: by S.B. Pichugin

Уравнение полной вероятности:

$$\begin{aligned}
& p_{0000}(t) + p_{0001}(t) + p_{0010}(t) + p_{0011}(t) + \\
& + p_{0100}(t) + p_{0101}(t) + p_{0110}(t) + p_{0111}(t) + \\
& + p_{1000}(t) + p_{1001}(t) + p_{1010}(t) + p_{1011}(t) + \\
& + p_{1100}(t) + p_{1101}(t) + p_{1110}(t) + p_{1111}(t) = 1.
\end{aligned} \quad (2)$$

На следующем шаге находили решение полученной системы уравнений размерности 16×17 . Для решения приведенной в таблице системы использовался метод обращения матриц.

Вероятности p_{ijkl} были обозначены через x_i , а коэффициенты при p_{0i} через a_{mn} и переведены в матричный вид:

$$A = \begin{pmatrix} a_{00} & a_{01} & a_{02} & \dots & a_{015} \\ a_{10} & a_{11} & a_{12} & \dots & a_{115} \\ a_{20} & a_{21} & a_{22} & \dots & a_{215} \\ \dots & \dots & \dots & \dots & \dots \\ a_{150} & a_{151} & a_{152} & \dots & a_{1515} \\ 1 & 1 & 1 & \dots & 1 \end{pmatrix} \quad (3)$$

$$X = \begin{pmatrix} x_0 \\ x_1 \\ x_2 \\ \dots \\ 1 \end{pmatrix} \quad B = \begin{pmatrix} 0 \\ 0 \\ 0 \\ \dots \\ 1 \end{pmatrix}$$

При использовании матричного способа решения данной системы обычно применяют формулу перемножения матриц:

$$A^{-1} \cdot B = X, \quad (4)$$

которая следует из выражения $A \cdot X = B$. Однако, в нашем случае мы оперируем с прямоугольной, а не квадратной матрицей.

При этом, если умножить обе части матричного выражения (4) на A^T , получим $(A^T \cdot A) \cdot X = A^T \cdot B$ квадратную матрицу и получим решение

$$(A^T \cdot A)^{-1} \cdot A^T \cdot B = X. \quad (5)$$

На базе решения (5) были получены значения вероятностей нахождения исследуемой системы в состояниях от «все приборы системы свободны» до «все приборы системы заняты», что позволяет оценить вероятность доставки сообщения по вероятности нахождения системы в заданном состоянии.

Для системы 2×2 , приведенной на рис. 2, уравнение системы имеет вид:

$$\begin{aligned}
& p_{a_m^1 a_m^2 a_n^3 a_n^4} \sum_{\substack{m=0; \\ m \neq n}}^{N=2^4} [f(a_m^1 - a_n^1) + f(a_m^2 - a_n^2) + \\
& + f(a_m^3 - a_n^3) + f(a_m^4 - a_n^4)] + \\
& + \sum_{\substack{n=0; \\ n \neq m}}^{N=2^4} p_{a_n^1 a_n^2 a_m^3 a_m^4} \cdot [f(a_n^1 - a_m^1) + f(a_n^2 - a_m^2) + \\
& + f(a_n^3 - a_m^3) + f(a_n^4 - a_m^4)] = 0,
\end{aligned} \quad (6)$$

$$\text{где } f(a_m^1 - a_n^1) = \begin{cases} 1, & \mu_{01} \\ 0, & 0 \\ -1, & \lambda_0 \end{cases},$$

$$f(a_m^2 - a_n^2) = \begin{cases} 1, & \mu_{02} \\ 0, & 0 \\ -1, & \lambda_0 \varepsilon_0 + \lambda_2(1 - \varepsilon_2) \end{cases},$$

$$f(a_m^3 - a_n^3) = \begin{cases} 1, & \mu_{21} \\ 0, & 0 \\ -1, & \lambda_2 \end{cases},$$

$$f(a_m^4 - a_n^4) = \begin{cases} 1, & \mu_{22} \\ 0, & 0 \\ -1, & \lambda_0(1 - \varepsilon_0) + \lambda_2\varepsilon_2 \end{cases},$$

$$f(a_n^1 - a_m^1) = \begin{cases} 1, & \lambda_0 \\ 0, & 0 \\ -1, & \mu_{01} \end{cases},$$

$$f(a_n^2 - a_m^2) = \begin{cases} 1, & \lambda_0\varepsilon_0 + \lambda_2(1 - \varepsilon_2) \\ 0, & 0 \\ -1, & \mu_{02} \end{cases},$$

$$f(a_n^3 - a_m^3) = \begin{cases} 1, & \lambda_2 \\ 0, & 0 \\ -1, & \mu_{21} \end{cases},$$

$$f(a_n^4 - a_m^4) = \begin{cases} 1, & \lambda_0(1 - \varepsilon_0) + \lambda_2\varepsilon_2 \\ 0, & 0 \\ -1, & \mu_{22} \end{cases}.$$

Были также получены [15; 16] соотношения для системы с произвольным числом межспутниковых трактов следующего вида, то есть для модели с m головными и n замыкающими приборами, нумерованными от 0 до $2x = m + n - 1$.

$$\begin{aligned} & -p_{a_m^1 \dots a_m^x} \sum_{\substack{m=0; \\ m \neq n}}^{N=2^x} [f(a_m^1 - a_n^1) + \dots + f(a_m^x - a_n^x)] + \\ & + \sum_{\substack{n=0; \\ n \neq m}}^{N=2^x} p_{a_n^1 \dots a_n^x} [f(a_n^1 - a_m^1) + \dots + f(a_n^x - a_m^x)] \end{aligned} \quad (7)$$

Как показано в [15], уравнение (7) применимо для систем любой размерности. Когда в

системе существуют низкоскоростные и высокоскоростные оси, модель сводится к двухосевой. Низкоскоростная ось моделирует работу абонентского тракта в НОСС, а высокоскоростная — работу межспутникового тракта, при произвольных числах направлений связи (лучей) в каждом тракте.

Зависимости вероятностей состояния системы от величины информационной нагрузки λ_0/μ_{01} , поступающей на вход абонентского тракта, в графическом виде представлены на рис. 5–7.

Из графиков, приведенных на рис. 5–7, следует, что вероятность занятости приемных трактов не превышает 2 % при величине поступающей нагрузки 20 % от пропускной способности абонентского тракта. То есть значительную часть времени абонентский тракт будет свободен.

Занятость передающего тракта составляет порядка 25 % и с ростом числа поступающих от абонентов сообщений снижается из-за учащения взаимных наложений данных абонентов (блокировок).

Вероятность занятости всех трактов спутника вначале нарастает с ростом входящей нагрузки, а затем начинает снижаться из-за того, что данные абонентов все чаще накладываются друг на друга, что приводит к потерям информации [14].




Рис. 5. Вероятность занятости приемных трактов
Источник: выполнено С.Б. Пичугиным

Figure 4. Probability of busy state of receiving paths
Source: by S.B. Pichugin




Рис. 6. Вероятность занятости передающих трактов
И с т о ч н и к: выполнено С.Б. Пичугиным

Figure 6. Probability of busy state of transmitting paths
S o u r c e: by S.B. Pichugin




Рис. 7. Вероятность занятости приемных и передающих трактов
И с т о ч н и к: выполнено С.Б. Пичугиным

Figure 7. Probability of busy state of receiving and transmitting paths
S o u r c e: by S.B. Pichugin

3. Этапы научного обоснования структурно-параметрического синтеза НОСС

При наличии данных о методах бортовой маршрутизации, обеспечения работы межспутниковых трактов и принципах их построения, разработанности и готовности к применению математического аппарата, предназначенного

для научного обоснования структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами и маршрутизацией данных на борту спутника, имеется возможность сформулировать этапность научного обоснования структурно-параметрического синтеза НОСС. Этот процесс включает следующие этапы:

1. Выбор метода маршрутизации в зависимости от развития технических средств и потребностей абонентов.

2. Формирование набора технических решений, реализующего выбранный метод маршрутизации и методик исследования.

3. Определение пороговых показателей, связанных с потребностями абонентов.

4. Оценка параметров функционирования технических решений в штатных и нештатных ситуациях с применением обоснованно выбранных методик.

5. Комплексное исследование реализуемости технических решений в рамках заданных сроков с применением обоснованно выбранных методик.

6. Заключение о реализуемости технических решений при синтезе НОСС.

На первом этапе синтеза из перечня разработанных методов маршрутизации отбирают те, которые наилучшим образом применимы для достижения целей применения НОСС в условиях текущего уровня потребностей абонентов, определяемых в первую очередь условиями конкуренции с наземными системами связи, а также техническими возможностями по удовлетворению указанных потребностей.

После того как методы маршрутизации информации для НОСС определены, наступает черед формирования перечня технических решений, реализующих выбранные методы в рамках синтезируемой структуры НОСС с учетом параметров функционирования последней.

На следующем этапе, применяя научные подходы, задают пороговые показатели параметров функционирования, позволяющих обеспечить функционирование НОСС и обеспечить потребности абонентов в космической связи, а также определенный задел на будущее.

В рамках очередного этапа осуществляют оценку параметров технических решений, перечень которых был определен ранее. Для оценки на основе научных подходов выбирают методики, которые в наибольшей степени соответствуют целям и задачам, определенным на предыдущих этапах синтеза НОСС. Рассматри-

ваться могут как штатные, так и нештатные ситуации функционирования НОСС, в зависимости от того, в каких условиях и какие задачи предстоит выполнять НОСС для обеспечения требований, предъявляемых абонентами к услугам космической связи.

Далее следует этап комплексного исследования реализуемости технических решений в рамках заданных сроков, с применением методик, обоснование выбора которых производилось на предыдущем этапе синтеза структуры НОСС.

По результатам комплексного исследования, в ходе которого полученные данные о технических характеристиках НОСС и сроках ее изготовления и ввода в строй сравниваются с пороговыми показателями, определенными в соответствии с потребностями абонентов, принимается окончательное решение о реализуемости, синтезированной НОСС с заданной структурой и параметрами.

В целом предложенная этапность научного обоснования структурно-параметрического синтеза НОСС позволяет обоснованно выбрать методы и средства для реализации такой конфигурации НОСС, которая дает возможность существенно улучшить характеристики космической связи в конкурентном отношении к наземным системам связи и объективно оценить ее возможности на текущий период и перспективу.

Заключение

Для научного обоснования научного обоснования структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными межспутниковыми трактами и маршрутизацией данных на борту спутника предложены принципы и этапность реализации технических решений, связанных с маршрутизацией данных на борту спутника и передачей данных по широкополосным МСТ. Разработан ряд методик, позволяющих оценить ряд технических характеристик синтезируемых НОСС, в том числе пропускную способность спутниковых и абонентских трактов и вероятность доставки информации по структуре НОСС. Сформиро-

ван перечень этапов структурно-параметрического синтеза низкоорбитальных систем связи с широкополосными МСТ и маршрутизацией данных на борту спутника и сформулировано содержание научного обоснования для каждого этапа из сформированного перечня.

Список литературы

1. Невдяев Л.В. Спутниковые системы Часть 1. Орбиты и параметры (дата размещения: 16.01.1999) URL: <https://www.osp.ru/nets/1999/01-02/143941> (дата обращения: 30.05.2025)
2. Макаренко С.И. Описательная модель системы спутниковой связи Iridium // Системы управления, связи и безопасности. 2018. № 4. С. 1–34. <https://doi.org/10.24411/2410-9916-2018-10401> EDN: VNVWWU
3. Пехтерев С.В., Макаренко С.И., Ковальский А.А. Описательная модель системы спутниковой связи Starlink // Системы управления, связи и безопасности. 2022. № 4. С. 190–255. <https://doi.org/10.24412/2410-9916-2022-4-190-255> EDN: QMOLDV
4. Бойкачев В.Н., Пичугин С.Б. Перспективы бортовой пакетной коммутации в низкоорбитальных сетях связи // Радиопромышленность. 2016. № 3. С. 71–74. <https://doi.org/10.21778/2413-9599-2016-3-71-74> EDN: WIOFBT
5. Пичугин С.Б. Абонентские и межспутниковые тракты в низкоорбитальных сетях связи // Радиопромышленность. 2019. Т. 29. № 3. С. 48–54. <https://doi.org/10.21778/2413-9599-2019-3-48-54> EDN: MXFWVT
6. Пичугин С.Б., Жуков А.О., Кучумов А.А., Сазонов В.В., Кумакшев И.М. Алгоритмы управления потоками информации в низкоорбитальных системах : монография. Москва : ФГБНУ «Аналитический центр», 2023. 279 с. <https://doi.org/10.55469/9785904670832> EDN: RGUOVR
7. Пичугин С.Б. Способ определения маршрута ретрансляции пакета сообщения и устройство для его осуществления. Патент на изобретение RU 2001532 C1, 15.10.1993. Заявка № 5031334 от 31.01.1992. EDN: YOREJZ
8. Пичугин С.Б. Спутниковый ретранслятор «Аксай». Патент на изобретение RU 2097926 C1, 27.11.1997. Заявка № 94018404/09 от 19.04.1994. EDN: LJYKUU
9. Пичугин С.Б. Спутниковый ретранслятор. Патент на изобретение RU 2673060 C1, 22.11.2018. Заявка № 2017140374 от 20.11.2017. EDN: RMMNDX
10. Пичугин С.Б. Спутниковый ретранслятор. Патент на изобретение RU 2783202 C2, 09.11.2022. Заявка № 2021105819 от 09.03.2021. EDN: LJPRZT
11. Пичугин С.Б. Спутниковый ретранслятор. Патент на изобретение RU 2793898 C1, 07.04.2023. Заявка № 2022127471 от 21.10.2022. EDN: LRGYWG

12. Пичугин С.Б. Модели массового обслуживания с простейшими потоками для низкоорбитальной спутниковой системы // Известия высших учебных заведений. Машиностроение. 2022. № 1 (742). С. 61–70. <https://doi.org/10.18698/0536-1044-2022-1-61-70> EDN: CGMMNP

13. Клейнрок Л. Теория массового обслуживания. Ленинград – Москва : Книга по Требованию, 2013. 429 с. ISBN 9785458355766

14. Пичугин С.Б. Двухфазная двухосевая модель многопролетной системы с дифференцированной пропускной способностью абонентских и межспутниковых трактов связи // Известия высших учебных заведений. Машиностроение. 2023. № 12 (765). С. 131–140. <https://doi.org/10.18698/0536-1044-2023-12-131-140> EDN: UUEGMI

15. Пичугин С.Б. Обобщённая модель спутника — ретранслятора с функцией маршрутизации и межспутниковыми трактами // Известия высших учебных заведений. Машиностроение. 2025. № 2 (779). С. 119–127. <https://doi.org/10.18698/0536-1044-2025-2-119-127>

16. Бондарева М.К., Дементьев А.Н., Жуков А.О., Пичугин С.Б. и др. Моделирование оперативности доставки информации орбитальной группировки дистанционного зондирования земли. Москва : Экспертноаналитический центр, 2023. 261 с. <https://doi.org/10.55469/9785904670825> EDN: NFSNHB

References

1. Nevdyayev LV. Satellite systems. Orbits and parameters. *Network world*. 1999;1. (In Russ).
2. Makarenko SI. Descriptive model OF IRIDIUM satellite communication system. *Systems of Control, Communication and Security*. 2018;(4):1–34. (In Russ). <https://doi.org/10.24411/2410-9916-2018-10401> EDN: VNVWWU
3. Pekhterev SV, Makarenko SI, Kovalskiy AA. Descriptive model of starlink satellite communication system. *Systems of Control, Communication and Security*. 2022;(4):190–255. (In Russ.) <https://doi.org/10.24412/2410-9916-2022-4-190-255> EDN: QMOLDV
4. Boykachyov VN, Pichugin SB. Perspectives of on-board packet routing in low-orbit communication networks. *Radio Industry*. 2016;(3):71–74. (In Russ.) <https://doi.org/10.21778/2413-9599-2016-3-71-74> EDN: WIOFBT
5. Pichugin SB. Subscriber and inter-satellite paths in LEO communications networks. *Radio Industry*. 2019;(3):48–54. (In Russ.) <http://doi.org/10.21778/2413-9599-2019-3-48-54> EDN: MXFWVT
6. Pichugin SB, Zhukov AO, Kuchumov AA, Sazonov VV, Kumakshev IA. *Algorithms for data flow control in LEO systems*. Moscow: Analytical Center, 2023:279. (In Russ.) <https://doi.org/10.55469/9785904670832> EDN: RGUOVR

7. Pichugin SB. *Method of determination of route of relaying of message package and device to implement it*. Russian Federation patent 2001532. 31 January 1992. 15 October 1993. EDN: YOREJZ
8. Pichugin SB. *Satellite retransmitter*. Russian Federation patent 2097926. 27 November 1997. EDN: LJYKUU
9. Pichugin SB. *Satellite transmitter*. Russian Federation patent 2673060. 20 November 2017. EDN: RMMNDX
10. Pichugin SB. *Repeater satellite*. Russian Federation patent 2783202. 09 March 2021. EDN: LJPRZT
11. Pichugin SB. *Relay satellite*. Russian Federation patent 2793898. 21 October 2022. EDN: LRGYWG
12. Pichugin SB. Simplest flow queuing models for LEO satellite system. *BMSTU Journal of Mechanical Engineering*. 2022;1:61–70. <http://doi.org/10.18698/0536-1044-2022-1-61-70>
13. Kleinrok L. *Queue Systems Theory*. Leningrad–Moscow: Kniga po Trebovaniu Publ.; 2013. (In Russ.) ISBN 9785458355766
14. Pichugin SB. Two-phased and two-axis model of multihop system with differentiated capacity of subscriber and intersatellite communication links. *BMSTU Journal of Mechanical Engineering*. 2023;12:131–140. (In Russ.) <https://doi.org/10.18698/0536-1044-2023-12-131-140>
15. Pichugin SB. Generalized model of a relay satellite with routing functionality and with intersatellite links. *BMSTU Journal of Mechanical Engineering*. 2025;2(779):119–127. (In Russ.) <http://doi.org/10.48550/arXiv.2005.12521>
16. Pichugin SB, Bondareva MK, Dementiev AN, Zhukov AO, Zhukov VA, Zhuravlev AP, et al. *Modelling of operability of data delivery from constellation for Earth remote probing*. Moscow: Analytical Center, 2023. (In Russ.) <https://doi.org/10.55469/9785904670825>

Сведения об авторе

Пичугин Сергей Борисович, доктор технических наук, ведущий научный сотрудник, ПАО РКК «Энергия» им. С.П. Королёва, Российская Федерация, 141070, Московская обл., г. Королёв, ул. Ленина, д. 4а; eLIBRARY SPIN-код: 5024-4804, ORCID: 0000-0002-1355-6708; e-mail: sergey.pichugin@rsce.ru

About the author

Sergey B. Pichugin, Doctor of Sciences (Techn.), Leading Science Associate, Rocket and Space Corp “Energia” named by S.P. Korolev, RSCE, 4a Lenin St, Korolev, Moscow region, 141070, Russian Federation; eLIBRARY SPIN-code: 5024-4804, ORCID: 0000-0002-1355-6708; e-mail: sergey.pichugin@rsce.ru



DOI: 10.22363/2312-8143-2025-26-3-227-244

EDN: VWVXUJ

Научная статья / Research article

Методология управления потоками целевой информации в космической системе ДЗЗ. Часть 4. Сетевые орбитальные группировки

А.В. Старков^{id}, А.А. Морозов^{id}✉

Московский авиационный институт (национальный исследовательский университет), Москва, Российская Федерация

✉ aamorozko@mail.ru

История статьи

Поступила в редакцию: 6 апреля 2025 г.

Доработана: 20 июня 2025 г.

Принята к публикации: 25 июня 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Исследование является продолжением цикла статей, посвященных системной организации математических моделей для решения задачи управления потоками целевой информации в космической системе ДЗЗ в части адаптации предложенного авторами методологического подхода для сетевых орбитальных группировок. Отличительной особенностью постановки задачи является необходимость решения задачи в сложной объектовой обстановке с применением перспективных межспутниковых каналов информационного взаимодействия для повышения оперативности и качества целевой информации. Предложена обобщенная форма представления модели потока целевой информации космической системы ДЗЗ как взаимосвязанная последовательность функций изменения объема информации при применении к нему соответствующего процесса обработки (функций изменения трафика). Рассмотрены общие подходы к решению оптимизационных задачи планирования наблюдений и межспутниковой передачи целевой информации. Проведена экспериментальная отработка решения задачи планирования и ретрансляции данных на пункты приема информации. Подтверждена возможность повысить информационную эффективность космических систем ДЗЗ за счет использования средств межспутниковой передачи данных.

Ключевые слова: дистанционное зондирование Земли, обработка данных, распределение информационных ресурсов, оптимизация, эффективность, планирование наблюдений, межспутниковый канал связи

Вклад авторов

Старков А.В. — введение, аннотация, утверждение окончательной версии; Морозов А.А. — программное обеспечение, визуализация, написание текста.

Для цитирования

Старков А.В., Морозов А.А. Методология управления потоками целевой информации в космической системе ДЗЗ. Часть 4. Сетевые орбитальные группировки // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 227–244. <http://doi.org/10.22363/2312-8143-2025-26-3-227-244>

© Старков А.В., Морозов А.А., 2025



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License
<https://creativecommons.org/licenses/by-nc/4.0/legalcode>

Methodology for Managing Target Information Flows in the Remote Sensing Space System. Part 4. Network Orbital Groupings

Alexander V. Starkov^{ORCID}, Alexander A. Morozov^{ORCID}✉

Moscow Aviation Institute (National Research University), Moscow, Russian Federation

✉ aamorozko@mail.ru

Article history

Received: April 6, 2025

Revised: June 20, 2025

Accepted: June 25, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. This study is the next in a series devoted to systematically organizing mathematical models for managing target information flows in remote sensing space systems. It adapts the methodological approach proposed by the authors for a network of orbital satellites. A distinguishing feature of the problem formulation is the necessity to solve the problem in a complex object environment using promising inter-satellite channels of information interaction to increase the efficiency and quality of the target information. A generalized form of representation of the target information flow model of the remote sensing space system is proposed as an interconnected sequence of functions for altering the amount of information when applying the corresponding processing process (traffic change functions) to it. This study explores the general methodologies employed in addressing optimization problems related to observation planning and inter-satellite transmission of target information. Experimental testing of the solution to the problem of planning and relaying data to information reception points has been carried out. The potential for enhancing the information efficiency of remote sensing space systems through the implementation of inter-satellite data transmission facilities has been validated.

Keywords: remote sensing of the Earth, data processing, distribution of information resources, optimization, efficiency, planning of observations, inter-satellite communication channel

Authors' contribution

Starkov A.V. — Research concept, Introduction, Abstract, approval of the final version; *Morozov A.A.* — software, visualization, writing.

For citation

Starkov AV, Morozov AA. Methodology for managing target information flows in the remote sensing space system. Part 4. Network orbital groupings. *RUDN Journal of Engineering Research*. 2025;26(3):227–244. (In Russ.) <http://doi.org/10.22363/2312-8143-2025-26-3-227-244>

Введение

Данная статья является продолжением серии статей [1–3], посвященных проблеме управления потоками целевой информации в космической системе (КС) дистанционного зондирования Земли (ДЗЗ). В них рассмотрена отработанная годами классическая схема построения системы ДЗЗ, состоящая из наземной инфраструктуры и орбитальной группировки, каждый космический аппарат (КА) которой связан информационными потоками с пунктами приема/передачи информации (ППИ). В такой постановке оператор КС на основе полученных заявок на проведение съемки определенных

районов формирует оперативный план наблюдений, включающий в себя моменты съемки, сброса и обработки целевой информации на ППИ, после отработки которого каждым КА орбитальной группировки (ОГ) результаты передаются потребителю.

Рассмотренная схема имеет целый ряд недостатков, ключевыми из которых являются оперативность передачи и качество целевой информации. Так, для российской системы ДЗЗ большую часть времени космические аппараты находятся вне зоны радиовидимости (ЗРВ). Например, для спутников на низких орбитах, близких к Международной космической станции, время нахождения в ЗРВ находится в

пределах 10–12 мин с последующей «мертвой зоной» в течение 80 мин. Проблема может быть решена кратным увеличением КА в составе ОГ ДЗЗ и изменением подходов к передаче целевой информации за счет дооснащения КА аппаратурой межспутниковой передачи данных. За счет такой аппаратуры появляется возможность рассматривать космический сегмент как информационную подсистему с сетевой организацией передачи целевой информации.

1. Формализация задачи

Анализ показывает, что изменение численности КА с одновременным существенным ростом количества и площади конкурентных заявок, в так называемой нагруженной целевой обстановке, для наземного сегмента требует лишь его масштабирования, а для космического сегмента — изменения подходов к планированию сеансов съемки и сброса целевой информации на ППИ. Это вызвано тем, что [4–6]:

1) существующие алгоритмы в полной мере не адаптированы к работе аппаратуры КА в смешанном режиме «сброс и съемка одновременно» и требуют корректировки;

2) объективно большая размерность оптимизационной задачи и связанных с ней ограничений приводит к тому, что классические методы оптимизации в задачах определения съемочного плана в ряде случаев не обеспечивают нахождение решения;

3) в части заявок потребителей нагруженная целевая обстановка характеризуется наличием большого числа пересечений (наложений) районов съемки с учетом требований по облачности. В этом случае возникает задача неформального решения вопроса о приоритизации, что реализовать в существующих алгоритмах расчетов затруднительно.

В результате возникает необходимость во введении дополнительных эвристических допущений, к числу которых можно отнести:

– территорию района интересов произвольной формы представлять в виде окружности габаритного радиуса либо объединения двух-трех окружностей;

– уменьшение уровней приоритетности с 5 до 3;

– осуществление сброса информации всегда на ближайший по времени ППИ.

Несмотря на такие допущения, решение строгой оптимизационной задачи в приемлемое время не дает необходимого результата, поскольку:

– аппроксимация территории районов интересов окружностями потребует большой дополнительной «холостой» работы аппаратуры наблюдения с последующей загрузкой ППИ;

– при наложении нескольких районов съемки, а также облачности недостаточно дискретизации уровней приоритетности, здесь речь скорее должна идти о формировании уровня приоритетности в виде вещественного числа;

– учет облачности приводит к неоднородности приоритетности как внутри отдельно взятого района наблюдения, так и всего задания на съемки в целом.

Таким образом, одним из направлений адаптации методологического подхода к новым условиям функционирования с использованием сетевых орбитальных группировок является развитие технологий планирования и передачи целевой информации в наземный сегмент (ретрансляции на ППИ) (рис. 1).

В проектировании систем ДЗЗ, в такой комплексной постановке, до настоящего времени данного рода задачи не решались, особенно это касается нагруженной целевой обстановки при большом количестве КА и объектов съемки [4–6]. В основе предложенного методологического подхода [1–3] лежит представление решения задачи как оптимизация последовательности выполнения процессов обработки, образующих совокупность взаимосвязанных математических моделей.

Каждая из этих моделей должна в условиях ограничений на входе иметь некий объем информации, преобразовывать его (уменьшать или увеличивать), вычислять системные показатели эффективности — время, требуемое для реализации процесса, и его условную стоимость.




Рис. 1. Развитие методологического подхода
Источники: выполнено А.А. Морозовым




Figure 1. Development of a methodological approach
Source: by A.A. Morozov

При этом общая математическая постановка задачи заключается в оптимизации маршрута прохождения заявки по узлам графа, в котором вершиной является заявка, а формализованные данные заявки передаются последовательно на элементы космического и наземного сегментов:

$$\Gamma = \{\Gamma_k, k = \overline{1, K}\} = \{(Q, L)_k, k = \overline{1, K}\}, \\ k_i = \text{const}, i = \overline{1, N}$$

с учетом возможности вычисления в каждом узле частных системных показателей, или их свертки, при наличии текущих ограничений.

В нашем случае, когда состав подсистемы ограничен компонентами космического сегмента, объективное свертывание позволяет перейти к частным показателям, характеризующим их эффективность целевого функционирования, которыми являются ценность информации и оперативность (время) ее ретрансляции в наземный сегмент. При этом оба этих частных показателя объединяет число КА ОГ ДЗЗ.

1.1. Оптимизация планирования съемки

Как правило, потребитель формирует заявку с указанием ее важности (приоритета). С точки зрения оператора системы важность заявки однозначно определяет ее условную стоимость. При этом пространственная протяженность объектов съемки и ограниченность полосы захвата аппаратуры наблюдения приводит к тому, что выполнение заявки происходит за несколько проходов, при этом интервал планирования ограничивает возможности по ее выполнению в полном объеме. Ценность в этом случае может быть определена как совокупность условных стоимостей наблюдаемых элементарных районов, входящих в заявки потребителей. Таким образом, в качестве частного показателя эффективности в задаче распределения целевой информации космического сегмента КС ДЗЗ в части оптимизации планирования съемки можно принять сумму всех условных стоимостей наблюдаемых элементарных районов при ограничениях на:

- условия работы целевой аппаратуры;
- внешние условия наблюдения;
- облачность в районах съемок.

При формировании условной стоимости элементарного района необходимо учитывать:

- приоритетность точки в рамках поданной заявки;
- наложение районов съемок;
- имеющийся, возможно неформальный, опыт планирования.

Условная стоимость съемки одного элементарного района определяется величиной

$$J_{ij} = C_{ij} \left(1 - \frac{|Q_{ij}|}{Q_{\max}} \right), \quad i = \overline{1, n}, \quad j = \overline{1, m}, \quad (1)$$

где C_{ij} — условная стоимость элементарного района (i, j) ; второй множитель — коэффициент качества изображения, учитывающий особенности работы целевой аппаратуры, характеризующиеся снижением качества снимков районов, удаленных от линии надир, и достигающий наибольшего значения при съемке в надир и наименьшего значения — при съемке под углом $Q_{\max}$; n — число разбиений интервала $[-180^\circ, +180^\circ]$ по долготе; m — число разбиений интервала $[-90^\circ, +90^\circ]$ по широте.

Критерий, характеризующий ценность отснятой информации k -м КА ОГ на интервале $[t_0, T]$, представляет собой линейную аддитивную функцию:

$$J_k(u_k, \theta_k(u_k)) = \sum_{j=1}^N \sum_{i=1}^M J_{ij}(u_k, \theta_k(u_k)). \quad (2)$$

Ценность отснятой информации всеми КА ОГ на интервале планирования $[t_0, T]$ представляет собой совокупность зависимых друг от друга частных критериев:

$$I(u) = J(u, \theta(u)) = \{J_k(u_k, \theta_k(u_k)), k = \overline{1, K}\}, \quad (3)$$

где u_k — стратегия управления бортовой съемочной аппаратурой k -го КА; $\theta_k(u_k)$ — соот-

ветствующая этой стратегии программа переориентации съемочной аппаратуры. Фактически значение критерия представляет собой совокупную условную стоимость снимков земных объектов, совершенных за интервал планирования $[t_0, T]$.

С учетом введенных обозначений оперативный съемочный план, как совокупность программ съемок земных объектов каждым КА, можно записать:

$$\Pi_c = \{ \Pi_{ck}(u) = (u_k, \theta_k(u_k)), k = \overline{1, K} \}. \quad (4)$$

Частная задача планирования формулируется следующим образом: при заданной матрице стоимости определить такую совокупность стратегий управления $u^* = \{u_k, k = \overline{1, K}\}$ бортовой съемочной аппаратурой КА и соответствующих им программ переориентации съемочной аппаратуры $\theta^* = \{\theta_k, k = \overline{1, K}\}$, которые формируют рациональный план оперативной съемки земных объектов из условия максимизации критериальных функций (3):

$$\Pi_c^* = (u^*, \theta^*(u^*)) = \arg \max_{\substack{u \in U \\ \theta \in \Theta}} [J(u, \theta(u))], \quad (5)$$

где U , Θ — соответственно множества допустимых стратегий управления бортовой съемочной аппаратурой и программ ее переориентации для всех КА системы при соблюдении ограничений:

- на время маршрута:

$$t_{\min}^r \leq t_k^r \leq t_{\max}^r, k = \overline{1, K}; \quad (6)$$

- на межмаршрутный интервал:

$$t_k^{rr} \leq t_{\max}^{rr}, k = \overline{1, K}; \quad (7)$$

- на внешние условия съемки (освещенность, минимальный и максимальный углы Солнца);

- на емкость бортового запоминающего устройства (БЗУ) КА:

$$V_i \leq V_{\max k}, k = \overline{1, K}; \quad (8)$$

- на максимально допустимый угол визирования КА для наблюдаемого земного объекта:

$$|\theta_k| \leq \theta_{\max k}, k = \overline{1, K}; \quad (9)$$

- на скорость переориентации КА:

$$|\dot{\theta}_k| \leq \dot{\theta}_{\max k}, k = \overline{1, K}; \quad (10)$$

- на учет облачности в районе съемок.

Как было сказано выше, на основе условных стоимостей элементарных районов на поверхности Земли формируется обобщенная для всех КА ОГ ДЗЗ заявка.

При формировании исходных данных по условным стоимостям элементарных районов важным является их визуальное представление. Для удобства можно использовать стандартное графическое 24-битное BMP-изображение ($RGB24bit$), в котором в трех битах (R, G, B) сохранять условную стоимость элементарного района с использованием операции суммирования (рис. 2):

$$\begin{aligned} (R, G, B)_{01+02} = \\ = (R_{01} + R_{02}, G_{01} + G_{02}, B_{01} + B_{02}), \end{aligned} \quad (11)$$

где R, G, B — биты красного, зеленого и синего в пикселе $RGB24bit$ изображения. В качестве примера можно привести изображение в градациях серого, в котором биты R, G, B одинаковы.

Основой для решения задачи подготовки исходных данных является определение способов преодоления неопределенностей при формировании условной стоимости элементарных районов, связанных с наложением заявок, в том числе имеющих различный приоритет (рис. 2). Один из способов предполагает различные варианты скаляризации [7–9]. Их существенным недостатком является то, что экспертная оценка, заложенная в них, является статичной, без обратной связи по результатам практического применения и внесения оперативных изменений в процесс планирования.




Рис. 2. Условная стоимость элементарных районов – визуальное представление
Источник: выполнено А.А. Морозовым

Figure 2. The visual representation of the conditional cost of elementary areas.
Source: by A.A. Morozov

Наиболее перспективным является группа способов, основанная на неформальном анализе множества исходных вариантов решений (рис. 3) [10]. При этом скаляризация является одним из вариантов такого анализа, где возможно использование специализированной искусственной нейронной сети (ИНС). Такой подход, помимо привлечения экспертов, предпо-

лагает обратную связь (обучение) по результатам функционирования системы. По сути, задачами ИНС являются анализ и обобщение информации о заявках, их приоритетности с учетом возможных пересечений районов, метеопрогнозов и на этой основе формирование условной стоимости элементарного района наблюдения (рис. 3).




Рис. 3. Неформальный анализ с использованием специализированной нейронной сети
Источник: выполнено А.А. Морозовым

Figure 3. Informal analysis using a specialized neural network
Source: by A.A. Morozov

1.2. Ретрансляция в ППИ

Существенное повышение оперативности передачи информации при рациональном построении ОГ [13] может быть достигнуто следующими способами:

- ретрансляцией целевой информации посредством КА-ретрансляторов на геостационарных орбитах (ГСР);
- применением средств сжатия данных;
- использованием перспективных каналов межспутниковой передачи целевой информации.

Передача данных по схеме

КА→КА ГСР→ППИ,

на первый взгляд, решает проблему оперативности передачи данных, а также накопления большого количества данных в памяти КА. Однако при кратном увеличении числа КА ДЗЗ в современных условиях это потребует кратного увеличения дорогих в производстве и обслуживании КА ГСР, что автоматически нивелирует экономический эффект от развертывания крупной группировки КА ДЗЗ.

При использовании различных технологий сжатия изображений, передаваемых в потоке данных, на первый план выходит проблема достоверности восстановленных данных в ППИ для их дальнейшей тематической обработки. Это приводит к необходимости использования сложного помехоустойчивого кодирования и передачи информации.

В качестве альтернативы предлагается рассмотреть технологию функционирования космической системы ДЗЗ как сетевой орбитальной группировки с модернизированным антенно-фидерным устройством (АФУ) на борту каждого КА, способным к ретрансляции данных внутри ОГ КА ДЗЗ. Такой подход, с одной стороны, позволит более оперативно решать задачу ретрансляции данных на уровне не хуже передачи по схеме КА→КА ГСР→ППИ, а с другой — уменьшить влияние помех на итоговую достоверность полученной информации ДЗЗ.

При этом существующая технология передачи данных [11–13] с космических аппаратов

дистанционного зондирования Земли на наземные пункты приема информации (ППИ) или с ППИ на другой ППИ с помощью спутника-ретранслятора характеризуется некоторыми негативными факторами, среди которых требуется обращать внимание на невозможность оперативного приема данных, необходимость хранения большого количества данных в бортовом запоминающем устройстве (БЗУ) космического аппарата (КА), а также достоверность информации на выходе тракта высокоскоростной радиолинии (ВРЛ), выраженную средней вероятностью ошибки на бит информации [14–15].

Далее будем полагать, что целевое функционирование КС ДЗЗ в части ретрансляции целевой информации рассматривается при следующих допущениях [16–17]:

- радиосигналы между КА и абонентскими терминалами распространяются прямолинейно и мгновенно и ретранслируются без временных задержек;
- абонентский терминал способен поддерживать непосредственную связь с каждым КА, находящимся в зоне его радиовидимости;
- влияние помех на процессы передачи информации исключается;
- орбитальная структура КС ДЗЗ за интервал планирования не изменяется.

Под планом оперативной коммутации межспутниковых каналов в КС ДЗЗ будем понимать упорядоченное множество временных последовательностей выполнения операций по передаче данных для каждого КА на интервале планирования, в том числе:

- моменты времени включения/выключения бортовой коммутирующей аппаратуры для установления непосредственной связи в сети КА (программа коммутации радиоканалов в межспутниковых линиях);
- моменты времени перекоммутации бортовой аппаратуры для непосредственной связи КА (программа перекоммутации радиоканалов в межспутниковых линиях);
- моменты времени установления непосредственной связи КА с абонентскими терминалами (программа коммутации радиоканалов в абонентских линиях).

Основные параметры такого плана составляют последовательности первого типа, поскольку именно они определяют эффективность целевого функционирования КС ДЗЗ [18]. Программы перекоммутации радиоканалов в межспутниковых линиях и коммутации радиоканалов в абонентских линиях, в свою очередь, определяются программой коммутации радиоканалов в межспутниковых линиях и техническими возможностями бортовой аппаратуры КА [11–13]. С учетом этого в дальнейшем под планом оперативной ретрансляции целевой информации будем понимать совокупность программ коммутации радиоканалов в межспутниковых линиях, образуемых каждым КА системы. Формально на интервале $[t_0, T]$ план может быть записан в виде

$$\Pi_r = \{ \Pi_{rk}(u_k) = (u_k, f_k(u_k)), k = \overline{1, K} \}, \quad (12)$$

где u_k — последовательность или стратегия управления бортовой коммутирующей аппаратурой k -го КА для установления связи в межспутниковых линиях; $f_k(u_k)$ — соответствующая стратегия управления программой перекоммутации радиоканалов в межспутниковых линиях k -го КА. Фактически значение критерия представляет собой совокупную условную стоимость снимков земных объектов, совершенных за интервал планирования $[t_0, T]$.

Частная задача планирования формулируется следующим образом: при заданном состоянии орбитальной группировки определить такую совокупность стратегий управления $u^* = \{u_k, k = \overline{1, K}\}$ бортовой коммутирующей аппаратурой КА ОГ, которые формируют рациональный маршрут ретрансляции сигнала с КА на ППИ из условия минимизации времени

$$\Pi_r^* = (u^*) = \arg \min_{u \in U} [T(u)], \quad (13)$$

где U — соответственно множество допустимых стратегий управления программой перекоммутации радиоканалов в межспутниковых

линиях, при соблюдении описанных выше ограничений; T — суммарное время передачи информации.

На этапе планирования целевого функционирования КС ДЗЗ может быть сформировано большое число альтернатив планов (9), отличающихся по количественному и качественному составу КА-ретрансляторов. Но не все из них могут быть реализованы из-за ограниченных технических возможностей бортовой аппаратуры КА.

Задача планирования процесса целевого функционирования КС ДЗЗ в части ретрансляции целевой информации состоит в формировании такого плана (9), который включал бы минимальное количество КА-ретрансляторов для установления и удержания каналов межспутниковой связи и позволял бы при своей реализации на интервале планирования достичь минимально возможного среднего времени доставки данных на НКИ при ограничениях:

- а) на загруженность бортового запоминающего устройства каждого КА;
- б) на загруженность каналов межспутниковой связи;
- в) на загруженность каналов приема информации в ППИ.

Модель целевого функционирования сетевой ОГ КА ДЗЗ на интервале планирования может быть представлена в виде ориентированного графа Γ , вершины которого представляют собой некое множество целевых операций ОГ КА ДЗЗ, которые формируются в различные совокупности друг с другом с целью непосредственной передачи информационного потока, реализуемые в определенные интервалы времени. В свою очередь, дуги графа определяют связность и формируют совокупности операций выполнения вершин. Исходя из вышесказанного, математическое представление графа имеет вид

$$\Gamma = (Q, L) = (\{Q_i, i = \overline{1, N}\}, \{L_i, i = \overline{1, N}\}), \quad (14)$$

где $Q = \{q_j, j = \overline{1, B}\}$, где q_j — номера вершин графа; B — количество вершин;

$$L = \{(q_j, q_s), j = \overline{1, B}, s = \overline{1, B}\},$$

где q_j, q_s — являются обозначением дуги графа между q_j и q_s вершинами. При этом если дуга между вершинами отсутствует, то и пара (q_j, q_s) также не существует.

Такой граф Γ представим в виде матрицы, элементами которой являются данные о взаимосвязи вершин и возможных целевых операциях ОГ КА ДЗЗ:

$$\Gamma_c = \begin{bmatrix} z_1^1 & m_{11} & m_{12} & \dots & 0 & n_{11} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ z_i^1 & m_{i1} & m_{i2} & \dots & m_{ie} & n_{id} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ z_q^e & m_{q1} & m_{q2} & \dots & m_{ie} & n_{qd} \end{bmatrix} =$$

$$= \begin{bmatrix} z_i^1 & m_{i1} & \dots & m_{ie} & n_{id} \end{bmatrix}, i = \overline{1, q} \quad (15)$$

где q — количество строк матрицы Γ_c , что равно количеству уникальных вершин графа Γ , означающих наземные пункты приема данных, либо такому числу, что будет достаточно для описания всех маршрутов передачи целевых данных. Элементы $z_q^e, e = \overline{1, N_{KA}}$ означают количество целевых операций съемки ОГ КА ДЗЗ, выполнение которых начинается после выполнения предыдущей (при наличии) i -й операции. Элементы $m_{ie}, i = \overline{1, q}, e = \overline{1, N_{KA}}$ означают собой номера КА, используемых в данном маршруте передачи данных, при этом, если количество КА, используемых в маршруте передачи меньше, чем общее количество КА в рассматриваемой системе, вместо номеров КА применяются условные обозначения в виде 0 для поддержания прямоугольности матрицы. Элементы $n_{id}, i = \overline{1, q}, d = \overline{1, N_{ППИ}}$ означают номера ППИ, используемые в данном маршруте передачи данных и являющиеся в строке последним элементом. Размерность матрицы Γ_c

напрямую связана с количеством запланированных целевых операций съемки ОГ КА ДЗЗ и количеством узлов для передачи данных.

2. Общий подход к решению оптимизационной задачи

2.1. Построение рационального плана съемки

В нашем случае, когда имеются большое число КА ОГ и нагруженная объектовая обстановка, появляется задача многокритериальной оптимизации [19–20] в качестве задачи одновременной минимизации некоторой совокупности критериев $\{J_k(u_k, \theta_k(u_k)), k = \overline{1, K}\}$ как суммарной стоимости попавших в поле зрения аппаратуры наблюдения каждого КА ОГ элементарных районов с учетом ограничений (6)–(10). Следует отметить, что строго математически задача в такой постановке смысла не имеет, так как минимумы отдельных критериев оптимальности в общем случае достигаются при разных значениях аргумента [7–9]. Однако современные методы принятия решений в случае многокритериальной неопределенности, подкрепленные оптимизационными процедурами, могут помочь выбрать рациональное решение [7–9].

В нашем случае можно воспользоваться достаточно эффективным подходом, основанным на формировании контрольных значений для исходных критериев оптимальности J_k^* , в роли которых может выступать решение отдельных однокритериальных задач:

$$J_k^*(u_k^*, \theta_k^*(u_k^*)) = \arg \max_{\substack{u_k \in U \\ \theta_k \in \Theta}} [J_k(u_k, \theta_k(u_k))], \quad (16)$$

$$k = \overline{1, K}.$$

Решением задачи (16) является программа «идеального» крена, которой соответствует непрерывное изменение угла крена линии визирования, обеспечивающая получение максимальной условной стоимости при отсутствии ограничений на условия съемки. Если теперь ввести в рассмотрение некоторую скалярную

функцию, характеризующую степень этой близости, то ее можно использовать в качестве нового скалярного критерия оптимальности. В простейшем случае такой функцией может быть квадратичная форма вида

$$\tilde{J}(u, \theta(u)) = \sum_{k=1}^K (J_k(u_k, \theta_k(u_k)) - J_k^*)^2. \quad (17)$$

Непосредственное решение такой задачи представляет определенные трудности. Это вызвано в первую очередь тем, что имеется прямая зависимость решения для одного КА от результатов планирования для другого при динамическом изменении орбитальной обстановки. Возникает необходимость в запоминании будущей эволюции всей группировки КА на каждом шаге оптимизационной процедуры. Для разрешения такого «проклятия размерности» необходимо прибегать к различным приближенным методам, основанным на допущениях, к которым можно отнести следующие:

- совокупная стоимость тематического продукта на всем интервале планирования является суммой совокупных стоимостей на непересекающихся подынтервалах;

- совокупная стоимость на каждом подынтервале определяется как упорядоченная сумма стоимости попавших в поле зрения аппаратуры наблюдения КА элементарных районов при условии, что они не наблюдались другими КА;

- на каждом подынтервале программа изменения угла линии визирования аппаратуры наблюдения с учетом возможного изменения угла крена каждого КА формируется на основе программы «идеального» крена (2) и ограничений (6)–(10).

Это позволяет:

- перейти от неопределенной размерности задачи планирования, зависящей от многих, в том числе неформализуемых факторов, к задаче с прогнозируемой размерностью;

- за счет декомпозиции существенно сократить размерность подзадач, решаемых на различных этапах;

- при нагруженной объектовой обстановке гарантированно обеспечить нахождение рационального решения;

- гарантированно обеспечить разрешение неопределенностей, связанных с приоритизацией и учетом облачности в районах съемки.

Это дает возможность решать задачу построения рационального плана поэтапно:

- 1) определяется программа «идеального» крена θ_k^* на заданном интервале планирования;

- 2) определяется упорядоченная последовательность КА и подынтервалов планирования для дальнейшей кусочно-линейной аппроксимации программы «идеального» крена;

- 3) проводится кусочно-линейная аппроксимация «идеального» крена, обеспечивающая наименьшее отклонение, при условии выполнения ограничений (6)–(10);

Результатом оптимизации являются:

- план изменения угла крена линии визирования аппаратуры наблюдения в виде графической и текстовой информации;

- количественные параметры выполнения заявки в виде абсолютных показателей по площади наблюдаемых районов и их совокупной стоимости, и ее доли по отношению к общей заявленной площади при использовании результатов планирования.

2.2. Алгоритм ретрансляции данных на ППИ

Формально процесс поиска возможных маршрутов передачи данных сводится:

- к расширению списка маршрутов передачи данных на основе (15);

- отсечению заранее неудачных или наименее удачных маршрутов путем логического анализа из-за невозможности передать данные на конечный пункт приема (отсутствие целевых операций передачи данных после определенного времени или недостаток временного интервала для передачи данных с учетом заданных характеристик радиолиний между узлами), а также передача данных на уже существующий узел в данном маршруте (например, передача данных с КА № 1 на КА № 2 и снова на КА № 1).

Фактически предлагаемый подход состоит в построении модели целевого функциони-

рования ОГ КА ДЗЗ с учетом организации процедуры стандартной маршрутизации. Это позволяет значительно экономить технологические и временные ресурсы в ходе дальнейшего анализа возможностей реализации данных

маршрутов с учетом общей загруженности линий связи в системе.

Упрощенная блок-схема используемого в ПО алгоритма маршрутизации представлена на рис. 4.



Рис. 4. Блок-схема алгоритма ретрансляции данных на ППИ

И с т о ч н и к: выполнено А.А. Морозовым




Figure 4. A block diagram of the data relay algorithm on the FIR

S o u r c e: by A.A. Morozov

В представленной блок-схеме алгоритма маршрутизации основным упрощением является «закрытость» блока проверки всех записанных маршрутов на условие окончания поиска. Поскольку данный этап является самым важным, он является триггером, когда стоит закончить поиск дополнительных вариантов маршрутов или отметить заранее неудачные маршруты.

3. Результаты экспериментальной отработки

Ниже представлены результаты экспериментальной отработки предлагаемого подхода, учитывающего специфику сетевых орбиталь-




Рис. 5. Группировка элементарных районов для модельного примера

Источник: выполнено А.А. Морозовым

Figure 5. Grouping elementary districts for a model example

Source: by A.A. Morozov

Результат применения предлагаемых технологий планирования для нашего модельного примера наглядно показывает (рис. 6), что в условиях, приближенных к нагруженной целевой обстановки, когда элементарные районы конкурируют между собой по показателю условной стоимости, предлагаемые методические подходы гарантированно находят рациональный план проведения съемки.

На рисунке видно, что развороты по крену будут выполнены в сторону максимального захвата наиболее яркого изображения и, как следствие, более высокой условной стоимости элементарного района, при этом все ограничения

ных группировок ДЗЗ. Отработка представлена на модельных примерах, наглядно отражающих суть предлагаемых изменений. В качестве базовой для отработки выбрана существующая ОГ, состоящая из 5 КА типа «Канопус» и 13 наземных пунктов на территории Российской Федерации.

3.1. Экспериментальная отработка решения задачи планирования

Наиболее наглядно результаты планирования могут быть представлены для варианта, когда элементарные районы группируются так, что их условные стоимости образуют поле градиента (рис. 5).




Рис. 6. Визуализация плана съемки для модельного примера

Источник: выполнено А.А. Морозовым

Figure 6. Visualization of the shooting plan for a model example

Source: by A.A. Morozov

выполняются. На рис. 6 зеленым цветом отмечена полоса захвата для положительного крена, желтым — для отрицательного. Красным цветом обозначена полоса захвата.

3.2. Экспериментальная отработка ретрансляции данных на ППИ

Целью экспериментальной отработки являлось подтверждение возможности реализации ретрансляции данных с КА на ППИ с одновременным определением возможных параметров ОГ. Ниже представлены сравнительные результаты для различных вариантов ретрансляции (рис. 7–9).




Рис. 7. Среднее время передачи целевой информации от КА на ППИ
Источник: выполнено А.А. Морозовым




Figure 7. The average time of transmission of target information from the spacecraft to the FIR
Source: by A.A. Morozov




Рис. 8. Усредненное выполнение возможных съемок при планировании ОГ КА ДЗЗ
в различных вариантах распределения целевой информации
Источник: выполнено А.А. Морозовым




Figure 8. The average performance of possible surveys during the planning of remote sensing equipment in various target information distribution options
Source: by A.A. Morozov




Рис. 9. Общий объем целевой информации в зависимости от различных вариантов распределения целевой информации
Источники: выполнено А.А. Морозовым




Figure 9. The total amount of target information depends on the different target information distribution options
Source: by A.A. Morozov

Заключение

В результате системного анализа существующей космической системы ДЗЗ, в том числе ее информационных продуктов и рабочих процессов, предложено дальнейшее развитие единого методического подхода к решению задачи управления потоками целевой информации в части детального учета процессов планирования работы целевой аппаратуры КА и использования перспективных межспутниковых каналов передачи целевой информации.

Основой предлагаемых изменений является совместное решение двух частных задач:

1) задачи планирования съемки в условиях нагруженной целевой обстановки (большое количество КА и разнородных объектов для съемки);

2) задачи дополнения классических каналов передачи информации между КА и ППИ широкополосными межспутниковыми каналами.

В части решения задачи планирования съемки предложено перейти от формализации отдельных заявок в виде описания их приоритетности и дополнительных ограничений к формализованному единому представлению заявок в виде совокупности условной стоимости элементарных районов, являющейся неформальной сверткой самих заявок, их условной стоимости, наложения районов, а также влияния внешних факторов на необходимость проведения съемки (метеопрогноза).

В части решения задачи ретрансляции целевой информации предложены и проанализированы перспективные технологии организации межспутниковой связи, целью которых, с одной стороны, является обеспечение возможности для более оперативного решения задачи передачи данных и уменьшения времени между съемкой и сброса результатов на ППИ, а с другой — снижение влияния различных условий на итоговую достоверность полученной информации ДЗЗ, тем самым повысив ее условную стоимость. Подтверждена возможность существенно повысить информационную эффективность КС ДЗЗ за счет использования средств межспутниковой передачи данных.

Список литературы

1. Старков А.В., Емельянов А.А., Гришанцева Л.А., Жуковская К.И., Морозов А.А., Тришин А.А. Методология управления потоками целевой информации в космической системе дистанционного зондирования Земли. Часть 1. Формализация задачи // Вестник Российского университета дружбы народов. Серия: Инженерные исследования, 2021. Т. 22. № 1. С. 54–64. <https://doi.org/10.22363/2312-8143-2021-22-1-54-64> EDN: EWFUYU
2. Старков А.В., Емельянов А.А., Гришанцева Л.А., Жуковская К.И., Морозов А.А., Тришин А.А. Методология управления потоками целевой информации в космической системе дистанционного зондирования Земли. Часть 2. Формирование системы взаимосвязанных математических моделей // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2021. Т. 22. № 2. С. 148–161. <https://doi.org/10.22363/2312-8143-2021-22-2-148-161> EDN: YDRRYG
3. Emelianov A.A., Grishantseva L.A., Zubkova K.I., Malyshev V.V., Nam N.V.H., Starkov A.V., Win Z.Y. Mathematical model of ERS data processing ground segment operation in terms of processing distribution // *Advances in the Astronautical Sciences*. 2020. Vol. 170. P. 495–504. EDN: QUXMHN
4. Емельянов А.А. Многоспутниковые орбитальные группировки: подходы к управлению и применению // Материалы 21-й Международной конференции «Современные проблемы дистанционного зондирования Земли из космоса». Москва, 2023. С. 2. EDN: NUTSXP
5. Хайлов М.Н., Заичко В.А., Тюлин А.Е., Емельянов А.А. Влияние цифровой трансформации общества на приоритеты развития ДЗЗ из космоса в России // Материалы 18-й Всероссийской открытой конференции «Современные проблемы дистанционного зондирования Земли из космоса»: электронный сборник материалов конференции. Институт космических исследований Российской академии наук. Москва, 2020. С. 3. EDN: KQPPBN
6. Тюлин А.Е., Селин В.А., Емельянов А.А. Актуализация приоритетов развития отечественной отрасли дистанционного зондирования Земли из космоса // Системный анализ, управление и навигация: тезисы докладов XXIII Международной научной конференции. Евпатория, 2018. С. 17–18. EDN: UVTUNQ
7. Malyshev V.V., Piyavsky B.S., Piyavsky S.A. A decision making method under conditions of diversity of means of reducing uncertainty // *Journal of Computer and Systems Sciences International*. 2010. Vol. 49. No. 1. P. 44–58. <https://doi.org/10.1134/S1064230710010065>
8. Golubev S.I., Malyshev V.V., Piyavskii S.A., Sypalo K.I. Decision Making in MultiCriteria Problems at the Image Design Stage of Aviation Rocket Technique // *Journal of Computer and Systems Sciences International*.

2020. Vol. 59. No. 2. P. 223–231. <https://doi.org/10.1134/S1064230720020057>

9. *Malyshev V.V., Piyavskii S.A.* The confident judgment method in the selection of multiple criteria solutions // *Systems Analysis and Operations Research*. 2015. Vol. 54. P. 754–764.

10. *Cong Y, Mei X, Liu T, Guan G.* Mission-capable satellite prediction method for ultra large remote-sensing satellite constellation based on BP neural network // *Research Square*. 2024. P. 1–23. <https://doi.org/10.21203/rs.3.rs-5351953/v1>

11. *Занин К.А., Клименко Н.Н., Москатынцев И.В.* Современные космические аппараты дистанционного зондирования Земли. Часть 1. Базовые проектные решения и пути модернизации космических аппаратов оптико-электронного наблюдения // *Воздушно-космическая сфера*. 2020. № 2 (103). С. 82–89. <https://doi.org/10.30981/2587-7992-2020-103-2-82-89> EDN: ТТОУЕР

12. *Занин К.А., Клименко Н.Н., Москатынцев И.В.* Современные космические аппараты дистанционного зондирования Земли. Часть 2. Особенности применения коммерческих космических аппаратов оптико-электронного наблюдения для решения задач в интересах государственных и военных потребителей // *Воздушно-космическая сфера*. 2020. № 3 (104). С. 90–101. <https://doi.org/10.30981/2587-7992-2020-104-3-90-101> EDN: FWWEDK

13. *Занин К.А., Москатынцев И.В.* Рациональное баллистическое построение космической системы радиолокационного наблюдения // *Полет. Общероссийский научно-технический журнал*. 2018. № 9. С. 23–29. EDN: XYXHPF

14. *Kadochnikov A., Tokarev A.* Cataloging system for Russian satellites remote sensing data: main characteristics and operating experience // *January 2020E3S Web of Conferences*. 2020. Vol. 223. No. 1. Article no. 03023. <https://doi.org/10.1051/e3sconf/202022303023> EDN: NTUUEF

15. *Ivanov A.Y., Kucheiko A.A.* Distribution of oil spills in inland seas based on SAR image analysis: a comparison between the Black Sea and the Caspian Sea // *International Journal of Remote Sensing*. 2015. Vol. 37. No. 9. P. 1–14. <https://doi.org/10.1080/01431161.2015.1088677> EDN: WNZLCV

16. *Болкунов А.И., Красильщиков М.Н., Малышев В.В.* Комплексная оценка эффективности навигационных спутниковых систем // *Известия Российской академии наук. Теория и системы управления*. 2022. № 3. С. 139–156. <https://doi.org/10.31857/S0002338822030039> EDN: WGKXTD

17. *Петрухин Б.М., Бычков Ю.В., Летагин А.А., Фурсаева Т.В.* О допустимом уровне рисков реализации программ стратегического планирования технологических инноваций в развитии космических средств //

Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2024. Т. 23. № 4. С. 89–98. <https://doi.org/10.18287/2541-7533-2024-23-4-89-98> EDN: JKPORD

18. *Балухто А.Н., Твердохлебова Е.М.* Современный подход к исследованию эффективности космических систем дистанционного зондирования Земли // *Космонавтика и ракетостроение*. 2022. № 3 (126). С. 122–136. EDN: UXKNFR

19. *Li X., Sun Ch., Fan H., Yang J.* Remote-Sensing Satellite Mission Scheduling Optimisation Method under Dynamic Mission Priorities // *MDPI Mathematics*. 2024. Vol. 12. No. 11. Article no. 1704. <https://doi.org/10.3390/math12111704> EDN: JJUBY

20. *Li Y., Hao X., Zhang L.* Data processing system design methodology for high-orbit remote sensing satellites // *Journal of Physics Conference Series*. 2025. Vol. 2977. No. 1. Article no. 012005. <https://doi.org/10.1088/1742-6596/2977/1/012005> EDN: NPQMQR

References

1. Starkov AV, Emelianov AA, Grishantseva LA, Zubkova KI, Morozov AA, Trishin AA. Methodology for managing the flows of target information in the remote sensing space system. Part 1. Task formalization. *RUDN Journal of Engineering Research*. 2021;22(1):54–64. (In Russ.) <https://doi.org/10.22363/2312-8143-2021-22-1-54-64> EDN: EWFUYU

2. Starkov AV, Emelianov AA, Grishantseva LA, Zubkova KI, Morozov AA, Trishin AA. Methodology for managing the flows of target information in the remote sensing space system. Part 2. Interrelated mathematical models systems formation. *RUDN Journal of Engineering Research*. 2021;22(2):148–161. (In Russ.) <https://doi.org/10.22363/2312-8143-2021-22-2-148-161>

3. Emelianov AA, Grishantseva LA, Zubkova KI, Malyshev VV, Nam NVH, Starkov AV, Win ZY. Mathematical model of ERS data processing ground segment operation in terms of processing distribution. *Advances in the Astronautical Sciences*. 2020;170:495–504. EDN: QUXMHN

4. Emelianov AA. Multiple satellite orbital groupings: management and application approaches. *Modern problems of remote sensing of the Earth from space: Proceedings of the 21st International Conference, 13–17 November, 2023*. Moscow. P. 2. (In Russ.) EDN: NUTSXP

5. Khailov MN, Zaichko VA, Tyulin AE, Yemelyanov AA. The impact of the digital transformation of society on the priorities of remote sensing development in Russia. *Modern problems of remote sensing of the Earth from space. Institute of Space Research of the Russian Academy of Sciences: Proceedings of the 18th All-Russian Open Conference, 16–20 November, 2020*. Moscow. P. 3. (In Russ.) EDN: KQPPBN

6. Tyulin AE, Selin VA, Yemelyanov AA. Updating the priorities of the development of the domestic industry of remote sensing of the earth from space. *System analysis, management and navigation: Proceedings of the XXIII International Scientific Conference, 18 July, 2018*. Yevpatoria. P. 17–18. (In Russ.) EDN: UVTUNQ
7. Malyshev VV, Piyavsky BS, Piyavsky SA. A decision making method under conditions of diversity of means of reducing uncertainty. *Journal of Computer and Systems Sciences*. 2010;49(1):44–58. <https://doi.org/10.1134/S1064230710010065>
8. Golubev SI, Malyshev VV, Piyavskii SA, Sypalo KI. Decision Making in MultiCriteria Problems at the Image Design Stage of Aviation Rocket Technique. *Journal of Computer and Systems Sciences International*. 2020;59(2): 223–231. <https://doi.org/10.1134/S1064230720020057>
9. Malyshev VV, Piyavskii SA. The confident judgment method in the selection of multiple criteria solutions. *Systems Analysis and Operations Research*. 2015;54: 754–764. <http://doi.org/10.1134/S1064230715050093>
10. Cong Y, Mei X, Liu T, Guan G. Mission-capable satellite prediction method for ultra large remote-sensing satellite constellation based on BP neural network. *Research Square*. 2024;1–23. <https://doi.org/10.21203/rs.3.rs-5351953/v1>
11. Zanin KA, Klimenko NN, Moskatinev IV. Modern Ers imagery satellites. Part 1. Basic design solutions and upgrade trends for ers imagery satellites. *Aerospace Sphere Journal*. 2020;(2):95–101. (In Russ.) <https://doi.org/10.30981/2587-7992-2020-104-3-90-101> EDN: FWWEDK
12. Zanin KA, Klimenko NN, Moskatinev IV. Modern ers imagery satellites. Part 2. Peculiarities of commercial imagery satellites application for governmental and military users. *Aerospace Sphere Journal*. 2020;(3):90–101. (In Russ.) <https://doi.org/10.30981/2587-7992-2020-104-3-90-101> EDN: FWWEDK
13. Zanin KA, Moskatinev IV. Rational ballistic construction of a space radar surveillance system. *Polet*. 2018;(9):23–29. (In Russ.) EDN: XYXHPF
14. Kadochnikov A, Tokarev A. Cataloging system for Russian satellites remote sensing data: main characteristics and operating experience. *January 2020E3S Web of Conferences*. 2020;223(1):03023. <https://doi.org/10.1051/e3sconf/202022303023>
15. Ivanov AY, Kucheiko AA. Distribution of oil spills in inland seas based on SAR image analysis: a comparison between the Black Sea and the Caspian Sea. *International Journal of Remote Sensing*. 2015;37(9):2101–2114. <https://doi.org/10.1080/01431161.2015.1088677> EDN: NTUUEF
16. Bolkunov AI, Krasil'shikov MN, Malyshev VV. Comprehensive assessment of the effectiveness of navigation satellite systems. *Journal of Computer and Systems Sciences International*. 2022;61(3):430–446. <https://doi.org/10.1134/S1064230722030030> EDN: PPWYMV
17. Petrukhin BM, Bychkov YuV, Letyagin AA, Fursaeva TV. On the acceptable level of risks in the implementation of strategic planning programs for technological innovations in the development of space systems. *Vestnik of Samara university. Aerospace and Mechanical Engineering*. 2024;23(4):89–98. (In Russ.) <https://doi.org/10.18287/2541-7533-2024-23-4-89-98> EDN: JKPOED
18. Balukhto AN, Tverdokhlebova EM. Modern approach to research of the effectiveness of space systems of remote sensing of the Earth. *Cosmonautics and Rocket Engineering*. 2022;(3):122–136. (In Russ.) EDN: UXKNFR
19. Li X, Sun Ch, Fan H, Yang J. Remote-sensing satellite mission scheduling optimisation method under dynamic mission priorities. *MDPI Mathematics*. 2024; 12(11):1704. <https://doi.org/10.3390/math12111704> EDN: JJUBTY
20. Li Y, Hao X, Zhang L. Data processing system design methodology for high-orbit remote sensing satellites. *Journal of Physics Conference Series*. 2025;2977(1): 012005. <https://doi.org/10.1088/1742-6596/2977/1/012005> EDN: NPQMOK

Сведения об авторах

Старков Александр Владимирович, доктор технических наук, профессор кафедры системного анализа и управления, Московский авиационный институт (национальный исследовательский университет), Российская Федерация, 125993, г. Москва, Волоколамское шоссе, д. 4; eLIBRARY SPIN-код: 5242-3413, ORCID: 0000-0002-2332-904X; e-mail: starkov@goldstar.ru

Морозов Александр Андреевич, аспирант кафедры системного анализа и управления, Московский авиационный институт (национальный исследовательский университет), Российская Федерация, 125993, г. Москва, Волоколамское шоссе, д. 4; eLIBRARY SPIN-код: 1394-5795, ORCID: 0000-0002-9325-3829; e-mail: aamorozko@mail.ru

About the authors

Alexander V. Starkov, Doctor of Technical Sciences, Professor of the Department of System Analysis and Management, Moscow Aviation Institute (National Research University), 4 Volokolamskoe Shosse, Moscow, 125993, Russian Federation; ORCID: 0000-0002-2332-904X, eLIBRARY SPIN-code: 5242-3413; e-mail: starkov@goldstar.ru

Alexander A. Morozov, Postgraduate student of the Department of System Analysis and Management, Moscow Aviation Institute (National Research University), 4 Volokolamskoe Shosse, Moscow, 125993, Russian Federation; eLIBRARY SPIN-code: 1394-5795, ORCID: 0000-0002-9325-3829; e-mail: aamorozko@mail.ru



DOI: 10.22363/2312-8143-2025-26-3-245-257

EDN: WFRGQE

Research article / Научная статья

Aerial Platforms for Exploration Under Extreme Conditions in the Venus Atmosphere

Victor A. Vorontsov, Michael V. Quispe Mendoza 

Moscow Aviation Institute (National Research University), Moscow, Russian Federation

✉ dixwmichael@gmail.com

Article history

Received: April 15, 2025

Revised: July 12, 2025

Accepted: July 21, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. This paper explores various aerial platforms for in-situ atmospheric exploration of Venus, emphasizing their potential integration into future missions. Platforms under consideration include fixed-altitude balloons, variable-altitude balloons, aircraft-like vehicles with three-dimensional maneuvering capabilities, and others. Design configurations of descent vehicles and deployment strategies for these platforms in Venus' atmosphere are discussed. Specific deployment mechanisms for balloons are detailed. The study also models the dynamics of spherical descent vehicles equipped with balloons, analyzing trajectory parameters during different phases. Results confirm the parameters remain within acceptable limits throughout descent.

Keywords: atmospheric descent, balloon probe, descent vehicle, deployment, trajectory modeling

Authors' contribution

Vorontsov V.A. — analysis of the data obtained, approval of the final version; *Quispe Mendoza M.V.* — developing the concept, conducting research, writing

For citation

Vorontsov VA, Quispe Mendoza MV. Aerial platforms for exploration under extreme conditions in the Venus atmosphere. *RUDN Journal of Engineering Research*. 2025;26(3):245–257. <http://doi.org/10.22363/2312-8143-2025-26-3-245-257>



Воздушные платформы для исследований в экстремальных условиях в атмосфере Венеры

В.А. Воронцов, М.В. Киспе Мендоза 

Московский авиационный институт (национальный исследовательский университет), Москва, Российская Федерация

 dixwmichael@gmail.com

История статьи

Поступила в редакцию: 15 апреля 2025 г.

Доработана: 12 июля 2025 г.

Принята к публикации: 21 июля 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Рассмотрены различные воздушные платформы для исследования атмосферы Венеры на месте, подчеркивается их потенциальная интеграция в будущие миссии. Рассматриваемые платформы включают аэростаты с фиксированной высотой полета, аэростаты с переменной высотой полета, летательные аппараты, подобные самолетам, с возможностью трехмерного маневрирования и др. Обсуждаются конструктивные конфигурации спускаемых аппаратов и стратегии развертывания этих платформ в атмосфере Венеры. Подробно описаны конкретные механизмы развертывания аэростатов. Исследование также моделирует динамику сферических спускаемых аппаратов, оснащенных воздушными шарами, анализируя параметры траектории на разных этапах. Результаты подтверждают, что параметры остаются в допустимых пределах на протяжении всего спуска.

Ключевые слова: атмосферный спуск, аэростатный зонд, спускаемый аппарат, развертывание, моделирование траектории

Вклад авторов

Воронцов В.А. — анализ полученных данных, утверждение окончательной версии; Киспе Мендоза М.В. — разработка концепции, проведение исследования, написание текста.

Для цитирования

Vorontsov V.A., Quispe Mendoza M.V. Aerial platforms for exploration under extreme conditions in the Venus atmosphere // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 245–257. <http://doi.org/10.22363/2312-8143-2025-26-3-245-257>

Introduction

Venus exploration programs rely on remote sensing and in-situ approaches, with the latter offering more accurate and reliable scientific data. To facilitate remote and contact exploration, a Venus mission typically comprises two main modules:

Orbiter: Operates around Venus to relay data back to Earth.

Descent Vehicle: a capsule able to carry scientific payloads and aerial platforms into Venus' atmosphere.

More than 40 Spacecrafts have been sent to Venus, but its extreme conditions (high tempe-

ratures, pressures, and clouds of sulfuric acid) limit the operational life of the probes to a few hours. The Soviet Union's *Vega* balloons in 1985 demonstrated the scientific potential of aerial platforms (APs), providing critical data of over two days at altitudes of 51–54 km, where conditions were moderate. These balloons carried a modest payload of 7 kg, including 1–2 kg of scientific instruments [1–4].

Future aerial platforms with large payloads, longer operational life, and variable operating altitudes could significantly enhance Venus exploration. Such advancements are pivotal for comparative planetology and habitability studies,

especially given the discovery of Earth-like exoplanets with Venusian characteristics. Current General Circulation Models (GCMs) fail to fully capture Venus' atmospheric dynamics, underscoring the need for improved data acquisition [5].

Increasing the number and diversity of aerial platforms is essential to address these challenges, requiring enhanced payload capacities and innovative mission architectures, in particular, aerial platforms, to expand the fields of the fields of study of the planet atmosphere and surface, as well as to obtain updated scientific information about the phenomena studied.

1. Aerial Platforms for Venus Exploration

The aerial platforms are designed to operate in the Venusian atmosphere where conditions are Earth-like, collecting data on atmospheric components and phenomena. This paper classifies these platforms based on altitude and positional control, evaluating them against three key criteria:

scientific capability, complexity, and technological readiness.

Three primary categories of aerial platforms are discussed:

Fixed-Altitude Balloons: Passive platforms that drift with wind currents at a stable altitude.

Variable-Altitude Balloons: Platforms capable of adjusting altitude to exploit atmospheric wind patterns for trajectory control.

Three-Dimensional Maneuvering Vehicles: Active platforms offering lateral and vertical mobility, including aircraft.

1.1. Fixed-Altitude Balloons

High-pressure balloons, such as those used in the Vega project, are ideal for stable operations in Venus' atmosphere. Despite turbulence-induced fluctuations, these platforms have proven effective for long-duration data collection. The Vega balloons, with a diameter of 3.5 m and a payload capacity of 7 kg, covered 11,000 km over 46 hours (Figure 1) [1; 2; 6–8].




Figure 1. Balloons with variable altitude

Source: by M.Ya Marov, U.T. Huntress [6]



Figure 2. Balloon probe with payload of the Vega project
Source: by Glaze et al. [20]

1.2. Variable-Altitude Balloons

Variable-altitude systems utilize mechanisms such as helium compression (mechanical or pump-based) to adjust buoyancy. These platforms can leverage vertical wind patterns, such as those identified by Venus Express, to navigate meridional wind currents, enabling controlled latitudinal movement (Figure 2) [5; 9; 10].

1.3. Three-Dimensional Maneuvering Vehicles

Fixed-wing aircraft powered by solar panels can fly high in the cloud layer using the intense solar flux on Venus. Instead of “floating”



Figure 4. Venus Atmospheric Maneuverable Platform (VAMP) — Inflatable airplane
Source: by G. Lee et al. [12]




Figure 3. Solar powered aircraft
Source: by Glaze et al. [20]

around the planet in the field of super-rotating atmospheric currents, a solar-powered aircraft must remain on the sunlit side of Venus, and this requires flying at speeds approaching 100 m/s, in an easterly direction opposite to the atmospheric flow. Compared to balloons, a solar-powered aircraft has the advantage of precise position control. However, dependence on electric propulsion also has limitations in the latitudes that can be observed. In addition, with existing and planned opportunities in the field of energy storage technologies, a solar-powered aircraft will not be able to cross the night side. It is also limited in how deep it can penetrate into the atmosphere, as dense clouds block the sunlight needed to power the device (Figure 3) [5; 10].

Venus Atmospheric Maneuverable Platform — An aircraft-type maneuverable aircraft with the weight of 450 kg, which is capable of independently entering the atmosphere of Venus from a low orbit at a speed, and is designed to survive under conditions of thermal pressure and hypersonic entry. During the flight phase, VAMP will move with minimal energy use at speeds of about 50–70 km/h in the upper and middle layers of the clouds of Venus and collect scientific data for transmission to Earth. VAMP is also quite stable and able to cope with the strong atmospheric winds of Venus, and can orbit the planet for up to a year (Figure 4) [5; 11; 12].

Next, we will examine in detail the related issues to the deployment and activation of aerial platforms (using aerostats as examples) as technical tools for research within the framework of integrated missions aimed at studying the atmosphere of Venus.

2. Deployment of Aerial Platforms

Descent Vehicles (DVs) serve as carriers and deployment systems for aerial platforms. This





paper reviews DV configurations and strategies for releasing balloons in Venus' atmosphere.

In practice, the following types of DVs have been utilized in various missions to explore the planets of the Solar System — Table 1 [1; 7; 16–17].

Designs for integrating aerial platforms within DVs are detailed, including configurations for spherical, conical, and segmental-conical vehicles. Deployment mechanisms for balloons are illustrated, emphasizing reliability during atmospheric entry — Table 2 [2; 7; 18].

Table 1





Types of Descent Modules and Their Characteristics

Shape of the DM	Description	Dimensions
Spherical	Ensures stability and compact payload arrangements.	
Conical	Accommodates elongated payloads, such as cameras, for high-altitude missions.	
Segmental-Conical	Optimized for aerodynamic efficiency and high-speed atmospheric entry.	
Venus-D Type	Features a sphere-cone shape for enhanced drag and stability.	

Source: by V.V. Efanov et al. [21]

Table 2

Layout Configurations of DVs with Aerial Platforms

Shape of the DM (Descent Modul)	Components
	Spherical-Type DV: 1 – Aerostat Probe (AP 1) 2 – Aerostat Probe (AP 2) 3 – Gliding Probe (GP) 4 – Service and Scientific Equipment Compartment of GP 5 – Drifting Probe / UAV Container 6 – Radar 7 – Landing Probe
	Conical-Type DV: 1 – Drogue Parachute 2 – Braking Parachute 3 – Descent Module 4 – Truss 5 – Communication Antenna with Orbital Module 6 – Main Parachute 7 – Aerostat Envelope 8 – Aerostat Envelope Inflation System 9 – Aerostat Gondola 10 – Aerostat Guide Rope 11 – Aerodynamic Shield 12 – Second Aerostat
	Segmented-Conical-Type DV: 1 – Parachute Container 2 – Aerostat Power Cone, containing the aerostat probe envelope 3 – Instruments 4 – Fore Screen 5 – Delta-V in the entry from orbit
	Venera-D'' Type DV 1 – Fore Screen 2 – Envelope 3 – Landing Module 4 – Parachute Container 5 – Aerostat Power Cone No. 1, containing the aerostat probe envelope 6 – Aerostat No. 2 7 – Aerostat No. 3

Source: by V.V. Efanov et al. [21]

The deployment of aerostats in the atmosphere of Venus occurs following the descent module's entry into the atmosphere during its descent

phase. The configurations for the spherical and segmented-conical descent modules are illustrated in Figures 5, 6.




Figure 5. Commissioning of balloons in the atmosphere of Venus from a spherical descent vehicle
Source: by V.V. Efanov et al. [21]




Figure 6. Commissioning of balloons in the atmosphere of Venus from a segmental-conical descent vehicle
Source: by V.V. Efanov et al. [21]

Table 3

Drag coefficient and application of different parachute parameters

Type	Drag coefficient	General application (Mach number, M)
Conical	0.75–0.90	Airdrop ($M < 0.5M < 0.5M < 0.5$)
Biconical	0.75–0.92	Airdrop ($M < 0.5M < 0.5M < 0.5$)
Disk-gap-band	0.52–0.58	Airdrop ($M < 0.5M < 0.5M < 0.5$)
Ring-slot	0.56–0.65	Extraction deceleration ($0.1 < M < 0.50.1 < M < 0.50.1 < M < 0.5$)
Ribbon	0.30–0.46	Supersonic deceleration ($1 < M < 31 < M < 31 < M < 3$)
Conical ribbon	0.50–0.55	Airdrop, deceleration ($1 < M < 31 < M < 31 < M < 3$)

Source: by S.C.G. Torres, V.A. Vorontsov [19]

3. Modeling the Motion of a Descent Vehicle in Venus' Atmosphere

The motion of a descent vehicle (DV), consisting of aerostats in Venus' atmosphere is analyzed using the example of a spherical-type DV. The process can be divided into the following stages¹ [7].

3.1. Stage One: Ballistic Motion of the DV in the Atmosphere

During this stage, the vehicle's velocity changes according to the laws of motion for a body falling through the air without a parachute (aerodynamic deceleration), transitioning from the second cosmic velocity to a near-sonic speed.

The equations of motion for the DV can be simplified and expressed as follows:

$$\begin{cases} \dot{V} = -\frac{\rho V^2}{2P_x} - g \sin\theta; \\ \dot{\theta} = -\cos\theta \left(\frac{g}{V} - \frac{V}{R_v + H} \right); \\ \dot{H} = V \sin\theta; \\ \dot{L} = \frac{V R_v \cos\theta}{R_v + H}, \end{cases} \quad (1)$$

where V — vehicle flight velocity, m/s; θ — trajectory inclination angle relative to the local horizon (angle between velocity vector and local horizontal plane), rad/deg.; H — altitude above the planet's surface, m; L — distance, m; R_v — average

planetary radius (for Venus, $R_v = 6051.8$ km); ρ — undisturbed flow density, kg/m³; g — gravitational acceleration at the DV's location, m/s²; P_x — ballistic parameter, kg/m².

3.2. Stage Two: Deployment of a Deceleration Parachute and Descent Using the Deceleration Parachute Until the Main Parachute is Deployed

The drag coefficient of the parachute depends on the canopy design, fabric type, permeability, flight speed, etc. Table 3 presents drag coefficient values for various parachute canopy types [19].

3.3. Stage Three: Separation of the Deceleration Parachute, Detachment of the Upper Hemispherical Heat Shield Containing Two Aerostats

Subsequently, the upper hemisphere descends on a parachute, followed by activation of the aerostats. For this stage, the equations of motion can be expressed as:

$$\begin{cases} \dot{V} = \frac{\rho g U \sin\theta - mg \sin\theta - \frac{1}{2} \rho V^2 (C_x S_m + C_p F_p + C_a F_a)}{(m + k \rho U)}; \\ \dot{\theta} = \frac{\rho g U \cos\theta - mg \cos\theta + \frac{m V^2}{R_v + H}}{(m + k \rho U) V}; \\ \dot{H} = V \sin\theta; \\ \dot{L} = \frac{V R_v \cos\theta}{R_v + H}, \end{cases} \quad (2)$$

¹ Ivanov NM, Dmitrievsky AA, Lysenko LN. *Ballistics and navigation of spacecraft*. Bustard Publ.; 2004. ISBN 5-7107-7085-X

where: m — mass of the DV (or its components), kg; C_x — DV drag coefficient (or its components); S_m — characteristic area of the DV; C_P — parachute drag coefficient; F_P — parachute area; C_a — aerostat drag coefficient; F_a — aerostat area; k — added mass coefficient; U — aerostat shell volume, m^3 .

3.4. Stage Four: Deployment of the Main Parachute, Descent, and Deceleration in Venus' Atmosphere

The simulation yielded trajectory parameter variation graphs over time (Figures 7–11).







Figure 7. Trajectory parameters of a spherical DV during motion in Venus' atmosphere (Stages 1–4)
Source: by M.V. Quispe Mendoza




a



b



c



d

Figure 8. Parameters during parachute deployment with variable masses:
a — altitude, km; *b* — trajectory angle, deg; *c* — overload, units; *d* — velocity, km/s

Source: by M.V. Quispe Mendoza




Figure 9. Parameters during upper hemisphere detachment:
a — altitude, km; *b* — trajectory angle, deg; *c* — overload, units; *d* — velocity, km/s
 Source: by M.V. Quispe Mendoza




Figure 10. Parameters during aerostat probe deployment:
a — altitude, km; *b* — trajectory angle, deg; *c* — overload, units; *d* — velocity, km/s
 Source: by M.V. Quispe Mendoza




Figure 11. Parameters during aerostat parachute deployment:
 a — altitude, km; b — trajectory angle, deg; c — overload, units; d — velocity, km/s

Source: by M.V. Quispe Mendoza

Conclusion

This study examines various aerial platforms carrying payloads for the contact and remote investigation of Venus' atmosphere and surface. The analysis of these platforms demonstrates enhanced potential for achieving scientific objectives in future missions.

Due to the extreme atmospheric conditions of Venus, prolonged contact-based studies are infeasible, emphasizing the importance of increasing the number of aerial platforms deployed to the planet, which necessitates a higher payload capacity for descent vehicles.

Simulation results confirm that trajectory parameters of a spherical descent vehicle with payloads up to 100 kg remain within acceptable limits across all motion stages, enabling the integration of advanced technical systems, such as aerial platforms, into the baseline design.

References

1. Moskalenko GM. *Mechanics of flight in the atmosphere of Venus*. Moscow: Mashinostroenie Publ.; 1978. (In Russ.) Available from: <https://djvu.online/file/iE9FdDdSMGlRj> (accessed: 12.02.2025).
2. Polishchuk GM, Pichkhadze KM. *Automated spacecraft for basic and applied scientific research*. Moscow: MAI-PRINT Publ.; 2010. (In Russ.) Available from: <https://djvu.online/file/Mk44ff4exnXMB> (accessed: 12.02.2025).
3. Limaye SS, Lebonnois S, Mahieux A, Patzold M, Bougher S, Bruinsma S, et al. The thermal structure of the Venus atmosphere: intercomparison of Venus Express and ground based observations of vertical temperature and density profiles. *Icarus*. 2017;294:124–155. <https://doi.org/10.1016/j.icarus.2017.04.020>
4. Zasova LV, Moroz VI, Linkin VM, Khatuntsev IV, Mayorov B. The structure of the atmosphere of Venus from the surface to 100 km. *Space Research*. 2006;44(4):381–400. (In Russ.) EDN: HVJINL
5. Venera-D: Expanding our Horizon of Terrestrial Planet Climate and Geology through the Comprehensive Exploration of Venus. *Scientific and Technical report of*

the Joint Scientific Working Group (JSWG) on the Venus-D project (IKI/Roscosmos — NASA Venera — D Joint Science Definition Team, JSDT). 2019;174. Available from: <https://www.lpi.usra.edu/vexag/reports/Venera-DPhaseIIFinalReport.pdf> (accessed: 12.02.2025)

6. Marov MYa, Huntress UT. *Soviet Robots in the Solar System. Mission Technologies and discoveries*. Moscow: Fizmatlit Publ.; 2018. (In Russ.) ISBN 978-5-9221-1741-8

7. Vorontsov VA, Malyshev VV, Pichkhadze KM. *System design of space landing vehicles*. Moscow: MAI Publ.; 2021. (In Russ.) ISBN 978-5-4316-0859-9

8. Sedykh OYu, Sysoev VK, Tkachenko AI, Khmel DS. Analytical review of the development of aerostatic probes for Venus. *Space engineering and Technologies*. 2024;2(45):38–52. (In Russ.) EDN: ZZSPCA

9. Coustenis A, Atkinson D, Balint T, Beauchamp P, Atreya S, Lebreton JP, et al. Atmospheric planetary probes and balloons in the solar system. *Proceedings of the Institution of Mechanical Engineers Part G Journal of Aerospace Engineering*. 2011;225(2):154–180. <https://doi.org/10.1177/09544100JAERO802>

10. Wilson CF, Chassefière E, Hinglais E, Baines KH, Balint TS, Berthelier JJ, et al. The 2010 European Venus Explorer (EVE) mission proposal. *Experimental Astronomy*. 2011;33(2–3):305–335. <https://doi.org/10.1007/s10686-011-9259-9>

11. Griffin K. Venus Atmospheric Maneuverable Platform (VAMP). A Concept for a Long-Lived Airship at Venus. 2013;22. Available from: <https://pdfs.semanticscholar.org/907a/12f8a798899c43990de49aef253456eae12.pdf> (accessed: 12.02.2025).

12. Lee G, Warwick S, Ross F, Sokol D. Venus Atmospheric Maneuverable Platform (VAMP). *Venus Modeling Workshop*. 2017;8006. Available from: <https://www.hou.usra.edu/meetings/venusmodeling2017/pdf/8006.pdf> (accessed: 25.04.2025).

13. Yatsenko MYu, Vorontsov VA. The concept of exploring Venus using a multirotor aircraft. *Collection of selected scientific reports on the results of the XLVI International Youth Scientific Conference Gagarin Readings*. Moscow: MAI. 2020;311–321.

14. Yatsenko MYu, Vorontsov VA. To the question of including additional technical means in the Venus exploration program. *Spacecraft and Technologies*. 2022;6(1):5–13. (In Russ.) <https://doi.org/10.26732/j.st.2022.1.01>

15. Yatsenko MYu, Vorontsov VA, Ryzhkov VV. Review of problematic issues of creating a multirotor aircraft for exploring Venus. *Engineering Journal: Science and Innovation*. 2023;14. (In Russ.) <https://doi.org/10.18698/2308-6033-2023-2-2255>

16. Kosenkova AV, Minenko VE, Bykovsky SB, Yakushev AG. Investigation of aerodynamic characteristics of alternative forms of a landing vehicle for studying Venus. *Engineering Journal: Science and Innovation*.

2018;11:5. (In Russ.) <https://doi.org/10.18698/2308-6033-2018-11-1826>

17. Kosenkova AV, Sedykh OYu, Simonov AV, Minenko VE. Investigation of reachable landing areas on the venus surface for various types of a lander. *Vestnik NPO Named After S.A. Lavochkin*. 2021;1:4–11. (In Russ.) <https://doi.org/10.26162/LS.2021.51.1.002> EDN: PNRHDA

18. Baibakov SN, Martynov AI. *From the orbit of a satellite into the eye of a typhoon*. Moscow: Nauka Publ.; 1986. (In Russ.)

19. Torres SCG, Vorontsov VA. Evaluation of the design parameters of the small lander, taking into account the uncertainty of the initial data. *Proceedings of MAI*. 2018;101:29. (In Russ.) EDN: VKBK0Y

20. Glaze LS, Wilson CF, Zasova LV, et al. Future of Venus Research and Exploration. *Space Science Reviews*. 2018;214:89. <https://doi.org/10.1007/s11214-018-0528-z>

21. Efanov VV, Karchaev HJ, Moishev AA, Shirshakov AE. *85 years of Lavochkin Association. A heroic past. A stable present. A bright future*. In 2 books. Book 2. *Space complexes for fundamental scientific research, created by Lavochkin Association*. Khimki: Lavochkin Association, 2023. (In Russ.) ISBN 978-5-4465-3631-3

Список литературы

1. Москаленко Г.М. Механика полета в атмосфере Венеры. Москва : Машиностроение, 1978. 232 с. URL: <https://djvu.online/file/iE9FdDdSMGlRj> (дата обращения: 12.02.2025).

2. Полищук Г.М., Пичхадзе К.М. Автоматические космические аппараты для фундаментальных и прикладных научных исследований. Москва : МАИ-Принт, 2010. 660 с. URL: <https://djvu.online/file/Mk44ff4exnXMB> (дата обращения: 12.02.2025).

3. Limaye S.S., Lebonnois S., Mahieux A., Patzold M., Bougher S., Bruinsma S., et al. The thermal structure of the Venus atmosphere: intercomparison of Venus Express and ground based observations of vertical temperature and density profiles // *Icarus*. 2017. Vol. 294. P. 124–155. <https://doi.org/10.1016/j.icarus.2017.04.020>

4. Засова Л.В., Мороз В.И., Линкин В.М., Хатунцев И.В., Майоров Б. Структура атмосферы Венеры от поверхности до 100 км // *Космические исследования*. 2006. Т. 44. № 4. С. 381–400. EDN: HVJINL

5. Venera-D: Expanding our Horizon of Terrestrial Planet Climate and Geology through the Comprehensive Exploration of Venus. *Scientific and Technical report of the Joint Scientific Working Group (JSWG) on the Venus-D project (IKI/Roscosmos — NASA Venera — D Joint Science Definition Team, JSDT)*. 2019;174. URL: <https://www.lpi.usra.edu/vexag/reports/Venera-DPhaseIIFinalReport.pdf> (дата обращения: 12.02.2025).

6. Маров М.Я., Хантесс Т. Советские роботы в Солнечной системе. Технологии и открытия. Москва : Физматлит, 2018. 616 с. ISBN 978-5-9221-1741-8

7. Воронцов В.А., Малышев В.В., Пичхадзе К.М. Системное проектирование космических десантных аппаратов. Москва : Изд-во МАИ, 2021. 256 с. ISBN 978-5-4316-0859-9
8. Седых О.Ю., Сысоев В.К., Хмель Д.С., Ткаченко А.И. Аналитический обзор разработок аэростатических зондов для Венеры // Космическая техника и технологии. 2024. № 2 (45). С. 37–52. EDN: ZZSPCA
9. Coustenis A., Atkinson D., Balint T., Beauchamp P., Atreya S., Lebreton J.P., et al. Atmospheric planetary probes and balloons in the solar system // Proceedings of the Institution of Mechanical Engineers Part G Journal of Aerospace Engineering. 2011. Vol. 225. No. 2. P. 154–180. <https://doi.org/10.1177/09544100JAERO802>
10. Wilson C.F., Chassefière E., Hinglais E., Baines K.H., Balint T.S., Berthelier J.J., et al. The 2010 European Venus Explorer (EVE) mission proposal. *Experimental Astronomy*. 2011;33(2–3):305–335. <https://doi.org/10.1007/s10686-011-9259-9>
11. Griffin K. Venus Atmospheric Maneuverable Platform (VAMP). A Concept for a Long-Lived Airship at Venus. 2013. 22 p. URL: <https://pdfs.semanticscholar.org/907a/12f8a798899c43990de49aef253456eaae12.pdf> (дата обращения: 12.02.2025).
12. Lee G., Warwick S., Ross F., Sokol D. Venus Atmospheric Maneuverable Platform (VAMP) — Pathfinder Concepts // Venus Modeling Workshop. 2017. URL: <https://www.hou.usra.edu/meetings/venusmodeling2017/pdf/8006.pdf> (accessed: 25.04.2025).
13. Yatsenko M.Yu., Vorontsov V.A. The concept of exploring Venus using a multirotor aircraft // Collection of selected scientific reports on the results of the XLVI International Youth Scientific Conference Gagarin Readings. Moscow: MAI. 2020. P. 311–321.
14. Яценко М.Ю., Воронцов В.А. К вопросу о включении в программу исследования Венеры дополнительных технических средств // Космические аппараты и технологии. 2022. Т. 6. № 1. С. 5–13. <https://doi.org/10.26732/j.st.2022.1.01>
15. Яценко М.Ю., Воронцов В.А., Рыжков В.В. Обзор проблемных вопросов создания мультироторного летательного аппарата для исследования Венеры // Инженерный журнал: наука и инновации. 2023. № 2 (134). С. 14. <https://doi.org/10.18698/2308-6033-2023-2-2255>
16. Косенкова А.В., Миненко В.Е., Быковский С.Б., Якушев А.Г. Исследование аэродинамических характеристик альтернативных форм посадочного аппарата на поверхность Венеры // Инженерный журнал: наука и инновации. 2018. № 11. С. 5. <https://doi.org/10.18698/2308-6033-2018-11-1826>
17. Косенкова А.В., Седых О.Ю., Симонов А.В., Миненко В.Е. Исследование достижимых районов посадки на поверхности Венеры для аппаратов различных типов // Вестник НПО им. С.А. Лавочкина. 2021. № 1 (51). С. 12–20. <https://doi.org/10.26162/LS.2021.51.1.002> EDN: PNRHDA
18. Байбаков С.Н., Мартынов А.И. С орбиты спутника в «глаз» тайфуна, Москва: Наука, 1986. 176 с.
19. Торрес С.К.Х., Воронцов В.А. Оценка проектных параметров малого спускаемого аппарата с учётом неопределённости исходных данных // Труды МАИ. 2018. № 101. С. 29. EDN: VKBKQY
20. Glaze L.S., Wilson C.F., Zasova L.V. et al. Future of Venus Research and Exploration // Space Science Reviews. 2018. Vol. 214. Article no. 89. <https://doi.org/10.1007/s11214-018-0528-z>
21. Ефанов В.В., Карчаев Х.Ж., Мошнеев А.А. и др. 85 лет НПО Лавочкина: героическое прошлое. Стабильное настоящее. Светлое будущее: в 2 кн. Книга 2 : Космические комплексы для фундаментальных научных исследований, созданные Ассоциацией имени Лавочкина. Химки : Ассоциация им. Лавочкина, 2023. ISBN 978-5-4465-3631-3

About the authors

Victor A. Vorontsov, Doctor of Sciences (Techn.), Professor of the Department 601 and 604, Moscow Aviation Institute (National Research University), 4 Volokolamskoe highway, Moscow, 125993, Russian Federation; eLIBRARY SPIN-code: 1063-3737; e-mail: victor-vorontsov@yandex.ru

Michael V. Quispe Mendoza, Ph.D Student of the Department 604, Moscow Aviation Institute (National Research University), 4 Volokolamskoe highway, Moscow, 125993, Russian Federation; eLIBRARY SPIN-code: 9178-6215, ORCID: 0009-0000-1833-2562; e-mail: dixwmichael@gmail.com

Сведения об авторах

Воронцов Виктор Александрович, доктор технических наук, профессор кафедры 601 и 604, Московский авиационный институт (национальный исследовательский университет), Российская Федерация, 125993, г. Москва, Волоколамское ш., д. 4; eLIBRARY SPIN-код: 1063-3737; e-mail: victor-vorontsov@yandex.ru

Киспе Мендоза Михаил Винсент, аспирант кафедры 604, Московский авиационный институт (национальный исследовательский университет), Российская Федерация, 125993, г. Москва, Волоколамское ш., д. 4; eLIBRARY SPIN-код: 9178-6215, ORCID: 0009-0000-1833-2562; e-mail: dixwmichael@gmail.com



DOI: 10.22363/2312-8143-2025-26-3-258-265

EDN: WGHNEE

Research article / Научная статья

Regression Neural Networks Advantage over Classical Regression Analysis

Olga A. Saltykova^{ID✉}, Vyacheslav D. Saushkin^{ID}

RUDN University, Moscow, Russian Federation

✉ olga_a_saltykova@mail.ru

Article history

Received: March 15, 2025

Revised: April 27, 2025

Accepted: May 12, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. In this study, two analyzing methods are used to predict housing prices in California: neural network forecasting methods and methods based on regression analysis. Using the example of individual forecast indicators produced on the basis of two methods, the forecast results are compared. The purpose of this study is to show that the accuracy of prediction by neural networks is higher than that of the classical method. The assessment is carried out by creating a product in Python, which was chosen for reasons of ease of implementation of this analysis, ease of implementation of the product, as well as ease of constructing a graphical analysis of the results obtained. An open data source consisting of sixteen thousand items, which includes a number of housing criteria and prices based on these criteria, was used as resources for training the neural network. A broad review of studies comparing the predictive performance of artificial neural network-based methods and other forecasting methods is conducted. Much attention is paid to comparing artificial neural network methods and linear regression methods. Based on the results of this study, it was revealed that the accuracy of the neural network model is much higher when predicting results using linear regression methods, depending on the introduction of new forecasting criteria.

Keywords: Neural network, Linear regression, MSE, R2, AUC-ROC, AUC-PR, Learning curve, Prediction

Authors' contribution

Saltykova O.A. — analysis of the data obtained, approval of the final version of the article; *Saushkin V.D.* — developing the concept of the article, conducting research, writing.

For citation

Saltykova OA, Saushkin VD. Regression neural networks advantage over classical regression analysis. *RUDN Journal of Engineering Research*. 2025;26(3):258–265. <http://doi.org/10.22363/2312-8143-2025-26-3-258-265>



Преимущество регрессионных нейронных сетей перед классическим регрессионным анализом

О.А. Салтыкова[✉], В.Д. Саушкин^{ORCID}

Российский университет дружбы народов, Москва, Российская Федерация

✉ olga_a_saltykova@mail.ru

История статьи

Поступила в редакцию: 15 марта 2025 г.

Доработана: 27 апреля 2025 г.

Принята к публикации: 12 мая 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Данное исследование посвящено анализу методов прогнозирования цен на жилье в Калифорнии. В нем применены два метода: нейросетевые методы прогнозирования и методы, основанные на регрессионном анализе. На примере отдельных прогнозных показателей, полученных на основе двух методов, сравниваются результаты прогноза. Цель исследования — показать, что точность прогнозирования с помощью нейронных сетей выше, чем у классического метода. Оценка осуществлена путем создания продукта на Python, который был выбран из соображений простоты проведения данного анализа, простоты внедрения продукта, а также простоты построения графического анализа полученных результатов. В качестве ресурсов для обучения нейронной сети был использован открытый источник данных, состоящий из шестнадцати тысяч элементов, который включает в себя ряд критериев оценки жилья и цен, основанных на этих критериях. Проведен широкий обзор исследований, сравнивающих эффективность прогнозирования с помощью методов, основанных на искусственных нейронных сетях, и других методов прогнозирования. Большое внимание уделено сравнению методов искусственной нейронной сети и методов линейной регрессии. По результатам этой работы было выявлено, что точность нейросетевой модели значительно выше при прогнозировании результатов с использованием методов линейной регрессии, в зависимости от введения новых критериев прогнозирования.

Ключевые слова: нейронная сеть, линейная регрессия, MSE, R2, AUC-ROC, AUC-PR, кривая обучения, прогнозирование

Вклад авторов

Салтыкова О.А. — анализ полученных данных, утверждение окончательного текста; Саушкин В.Д. — разработка концепции статьи, проведение исследований, написание текста.

Для цитирования

Saltykova O.A., Saushkin V.D. Regression neural networks advantage over classical regression analysis // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 258–265. <http://doi.org/10.22363/2312-8143-2025-26-3-258-265>

Introduction

Regression Analysis

The current realities of the modern economy lead to many risky challenges for companies in various industries. They are accompanied by drastic changes that negatively affect the company's performance and its sustainability as a system. These circumstances require organizations to make operational management decisions, their system flexibility, which can adapt to the influence of ran-

dom factors influencing it both internally and externally. However, in order for an enterprise to carry out competent management, there is a need to predict such situations, which leads to the search for tools for predicting and promptly responding to emerging negative situations [1; 2].

The fundamental criterion for competent management in organizations is the predictability of the system, in this case the organization is this system. This criterion is necessary for the premature neutralization of negative consequences

from the influence of various external and internal factors. For example, a number of key employees leave the organization; after such an event, the business must immediately respond and take various actions to eliminate the consequences. The best option would be to implement a department-function diagram, so that if several units suddenly leave the department, other participants in the process can take over their functions. Alternatively, another example, it is necessary to monitor the market for the inculcation of innovations to increase competitiveness. After receiving statistics about the market needs, the business needs to make a conclusion about what product the company needs to make. Recent events related to the pandemic have also hit the market hard, making it clear that systems are needed to offer management solutions that can keep costs to a minimum. All these and many other factors negatively affect organizations, in connection with which there was a need to introduce models that can warn in advance about such incidents, and offer ways to eliminate them.

As a rule, one of the best solutions will be to carry out statistical monitoring and data analysis through mathematical modeling of production processes. For which one of the most effective methods will be the using regression analysis, which allows you to predict the economic impact based on retrospective data.

The English statistician F. Galton [1] first introduced the term “regression”.

Regression analysis, derived from the Latin word “regression” meaning, “moving backwards”, is a comprehensive method for studying the interactions between various indicators. The key idea is to analyze the dependence of the effective indicator Y on a set of factor variables (for example, x_1, x_2, x_n), with each of the variables x_i making a certain contribution to the function $Y=f(x_i)$, which describes their combined impact on the result under study.

In the regression analysis process, the key is to establish exactly how these factor features affect the outcome measure and how changes in these features may affect the outcome. This study is based on the assumption that the performance indicator

dynamics directly depends on changes in factor characteristics. While other variables that may also have an effect on outcome are treated as constants or averages to focus on the main change factors.

Thus, regression analysis not only reveals relationships between variables, but also helps to understand how specific changes in some variables can systematically influence changes in others, providing valuable data for making informed decisions in various areas of scientific research.

In the statistical analysis arsenal, there are two main types of regression models, each of which serves to study the interactions between variables and their influence on the result under study.

A linear multiple regression model focused on studying the influence of one key factor attribute on a performance indicator, representing the relationship as a simple linear function. This means that changes in the performance indicator described as a direct consequence of changes in that factor.

On the other hand, a nonlinear multiple regression model includes several factor features, whose impact on the performance indicator can be described using various mathematical functions such as exponential, logarithmic, polynomial or power functions. These models make it possible to reflect more complex and multi-level relationships, where each factor characteristic can make its own unique contribution, which can enhance or weaken the influence of other factors.

It is especially important that both linear and nonlinear models can demonstrate both direct and inverse relationships between factor characteristics and the performance indicator. This means that an increase or decrease in one or more factor characteristics can lead to a corresponding increase or decrease in the effective indicator. Thus, understanding the structure of relationships between variables through these models opens up prospects for in-depth analysis and forecasting in various fields of scientific research.

Mathematical description of regression [3]:

The essence of regression is as follows: at the input we have a vector $\mathbf{X}$, we need to predict all values of $Y(x)$ see formula

$$\hat{Y} = X^T \hat{\beta}. \quad (1)$$

The error function is the standard deviation, see formula

$$E(\beta) = \sum_{i=1}^n (y_i - \hat{y}_{\text{right}})^2 = \sum_{i=1}^N (y_i - x_i^T \hat{\beta}_{\text{right}})^2. \quad (2)$$

This problem is solved by taking the derivative of SE equal to zero, see formula

$$\frac{\delta SE(J^\beta)}{\delta \beta} = 2 X^T (y - X\beta) = 0. \quad (3)$$

This will find a minimum, and since SE is a quadratic function, its minimum always exists. Therefore, it is not difficult to find β using formula

$$\hat{\beta} = (X^T X^{-1}) X^T y. \quad (4)$$

This completes the description of linear regression. In reality, linearity in the data is not always present, which leads to the need to introduce nonlinearity. Solving this problem on a large data set is a bad solution because it is not always possible. In such cases, it may be useful to train a neural network model to solve a regression problem, which has in its arsenal various methods based on gradient descent that provide predictors that are more accurate.

Regression Neural Network

A regression neural network is a type of artificial neural network specifically designed for analyzing and solving regression problems [4; 5]. These networks gracefully process continuous variables to produce quantitative predictions, unlike their classification cousins that define categories. Due to their ability to accurately predict numerical values, regression neural networks find their application in a wide range of problems. They play a key role in predicting asset prices, assessing economic performance, time series analysis and many other areas where the accuracy and reliability of forecasts is critical.

These networks are becoming an indispensable tool in industries that need to extract deep quantitative insights from complex data, providing professionals with valuable insights for informed decisions. In this context, regression neural net-

works do not just process information, they uncover hidden patterns and trends, turning raw data into strategic knowledge that allows for the development of optimal strategic decisions. Let's look at the key aspects of regression neural networks [6–8]:

Error optimization. The core of regression models is formed by loss functions such as mean square error (MSE) [9] and mean absolute error (MAE) [10], which allow us to estimate deviations between predicted and true values. In this case, the main task is to regularly reduce deviations, allowing you to learn from errors and correct predictions.

Architectural flexibility. The diversity of input data and unique task requirements dictate the design of regression networks, which can take the form of multilayer perceptrons (MLP) [11], convolutional neural networks (CNN) [12], or recurrent neural networks (RNN) [13].

1. Results

Predicate finalization. The final chord in a regression network melody is its output layer, usually containing a single neuron with linear activation or none at all. This allows the network to express continuous variables, thereby ensuring accuracy and consistency in the output.

Powerful optimization algorithms, including stochastic gradient descent (SGD), Adam and RMSprop, support the training efficiency of regression neural networks. These methods help reduce error on the training data, providing a fast and accurate approximation to the best possible prediction results. Each of these elements plays a critical role in the functioning of a regression neural network, making it not only a tool for completing tasks, but also a platform for innovation and discovery in applications ranging from financial forecasting to medical research [2].

The approach provided in this work visualizes the performance of two different models — a linear regression model and a multilayer perceptron (MLP) neural network — using two key indicators: mean square error (MSE) and R-square (R^2) [14]. These metrics are important for understanding how well each model predicts home prices in California's open housing dataset (Tables 1, 2).

Table 1

Data on housing characteristics in California

MedInc	House Age	AveRooms	AveBedrms	Popul	AveOccup	Latitude	Longitude	MedValue
8.3252	41.0	6.984127	1.023810	322.0	2.555556	37.88	–122.23	4.526
8.3014	21.0	6.238137	0.971880	2401.0	2.109842	37.86	–122.22	3.585
7.2574	52.0	8.288136	1.073446	496.0	2.802260	37.85	–122.24	3.521
5.6431	52.0	5.817352	1.073059	558.0	2.547945	37.85	–122.25	3.413

Source: by V.D. Saushkin

Table 2

Data on home prices in California

House_id	Price
1	4.526
2	3.585
3	3.521
4	3.413

Source: by V.D. Saushkin

Let's look at what each graph represents and the meaning of the results.

Learning curve. Learning curve is a graph showing changes in the performance of a neural model (Figure 1).

Mean Square Error (MSE). MSE is a measure of the root mean square difference between estimated values (predictions) and actual values. Essentially, it captures the deviation of forecasts from true values, with an emphasis on more severe penalties for more severe errors due to squaring each term.




Figure 1. Learning curve

Source: by V.D. Saushkin

Interpretation of the graph (Figure 2): The graph titled “MSE Comparison” for each model shows a bar indicating the MSE value obtained after testing each model. Lower MSE values are better because they indicate that the model's predictions are closer to the actual data. If one bar is significantly lower than the other is, it indicates that the model fits the test data better.

Data on the MSE indicators of linear regression and neural network: Linear Regression — MSE: 0.55, Neural Network — MSE: 0.26, which is two times less (Figure 2).

R-squared (R^2), also known as the coefficient of determination, measures the proportion of variance in a dependent variable that can be predicted from the independent variables. It indicates

the degree of fit and is therefore a measure of how well unseen patterns can be predicted by the model, with a value ranging from 0 to 1. An R^2 of 1 indicates that the regression predictions fit the data perfectly.

Interpretation of the graph (Figure 3): The graph titled “ R^2 Comparison” displays bars for each model’s R^2 score. Higher R^2 values are preferred because they indicate that the model is accounting for a greater proportion of the variance in the dependent variable.

A high R^2 means that the model explains most of the variability in the target variable based on its input characteristics.

Data on R^2 indicators of linear regression and neural network: Linear Regression — R^2 : 0.57, Neural Network — R^2 : 0.80.

Precision-Recall Curve (PR) [15–17] is a graph showing the relationship between correctly predicted positive observations — accuracy, and the proportion of correctly predicted actual positive observations. The values of this curve vary in the same way as for ROC. The graphs of these curves are shown in Figure 4.

These graphs show that the performance of the neural network is higher than the performance of regression analysis, for NN the indicator is equal 0.95, while for LR is equal 0.9.




Figure 2. Diagram of the root mean square error between linear regression and neural network
Source: by V.D. Saushkin




Figure 3. R -squared (R^2) diagram between linear regression and neural network
Source: by V.D. Saushkin




Figure 4. AUC-ROC and AUC-PR
Source: by V.D. Saushkin

Conclusion

Linear Regression vs. Neural Network. Comparing the two methods on each graph gives you an idea of which model works better on the dataset in its current configuration. If the neural network bars are higher on the R^2 graph and lower on the MSE graph, it means that the neural network has a higher prediction accuracy than the linear regression model.

It is very important to note that MLP may require tuning (e.g., adjusting the number of hidden layers, neurons, or iterations) to optimize its performance. Conversely, if linear regression is superior to or very close to MLP, it may indicate that the dataset is linearly separable or that the neural network needs additional functions and more complex architectures to exploit its capabilities.

This information helps decide which model to deploy based on the tradeoffs between complexity, performance, and computational cost. For example, if the improvement in MSE and R^2 is small for a neural network compared to a linear regression, you may prefer the simpler and more interpretable linear model, especially in contexts where model interpretability is critical.

Finally, these visual comparisons guide further exploration and tuning, providing an easy way to communicate model performance to stakeholders and make informed decisions about improving or deploying the model.

References

1. Arkes J. Regression analysis: a practical introduction. *Routledge*. 2023. <https://doi.org/10.4324/9781003285007>
2. Srilakshmi U, Manikandan J, Velagapudi T, Abhinav G, Kumar T, Dogiparthi S. A new approach to computationally-successful linear and polynomial regression analytics of large data in medicine. *Journal of Computer Allied Intelligence*. 2024;2(2):35–48. <https://doi.org/10.69996/jcai.2024009> EDN: CPWMHQ
3. Chatterjee S, Hadi AS. *Regression analysis by example*. John Wiley & Sons, 2015.
4. Chen Q, Sabir Z, Umar M, Baskonus HM. A Bayesian regularization radial basis neural network novel procedure for the fractional economic and environmental system. *International Journal of Computer Mathematics*. 2025;102(2):280–291. <https://doi.org/10.1080/00207160.2024.2409794>
5. Morland C, Tandetzki J, Schier F. An evaluation of gravity models and artificial neuronal networks on bilateral trade flows in wood markets. *Forest Policy and Economics*. 2025;172:103457. <https://doi.org/10.1016/j.forpol.2025.103457> EDN: WLWUFE
6. Levine H, Jørgensen N, Martino-Andrade A, Mendiola Ja, Weksler-Derri D, Jolles M, et al. Temporal trends in sperm count: a systematic review and meta-regression analysis of samples collected globally in the 20th and 21st centuries. *Human reproduction update*. 2023; 29(2):157–176. <https://doi.org/10.1093/humupd/dmac035> EDN: IXUWPZ
7. Jin B, Xu X. China commodity price index (CCPI) forecasting via the neural network. *International Journal of Financial Engineering*. 2025;1–27. <https://doi.org/10.1142/S2424786325500033> EDN: UFNNOO
8. Seifipour R, Mehrabian A. Application of Artificial Neural Networks in Economic and Financial Sciences. *IntechOpen*. 2025. <https://doi.org/10.5772/intechopen.1007604>
9. Guo R, Liu J, Yu Y. Digital transformation, credit availability, and MSE performance: Evidence from China. *Finance Research Letters*. 2025;72:106552. <https://doi.org/10.1016/j.frl.2024.106552> EDN: FARNAP
10. Zhang Y. et al. A sequential MAE-clustering self-supervised learning method for arrhythmia detection. *Expert Systems with Applications*. 2025;269:126379. <https://doi.org/10.1016/j.eswa.2025.126379> EDN: AYJFTC
11. Bashir T, Li X, Zhang L, Wang J, Jiang S, MaY, et al. Wind and solar power forecasting based on hybrid CNN-ABiLSTM, CNN-transformer-MLP models. *Renewable Energy*. 2025;269:126379. <https://doi.org/10.1016/j.renene.2024.122055> EDN: NRTAPU
12. Sakka ME, Ivanovich M, Chaari L, Mothe J. A Review of CNN Applications in Smart Agriculture Using Multimodal Data. *Sensors*. 2025;25(2):472. <https://doi.org/10.3390/s25020472> EDN: ITDWUD
13. Protoulis T, Kordatos I, Kalogeropoulos I, Sarimveis H, Alexandridis A. Control of wastewater treatment plants using economic-oriented MPC and attention-based RNN disturbance prediction models. *Computers & Chemical Engineering*. 2025;109009. <https://doi.org/10.1016/j.compchemeng.2025.109009> EDN: KEHEID
14. Dezfooli FP, Zoj MJV, Mansourian A, Youssefi F, Pirasteh S. GEE-based environmental monitoring and phenology correlation investigation using Support Vector Regression. *Remote Sensing Applications: Society and Environment*. 2025;37:101445. <https://doi.org/10.1016/j.rsase.2024.101445> EDN: UFXMYW
15. Oehr P. Interrelationships Among Sensitivity, Precision, Accuracy, Specificity and Predictive Values in Bioassays, Represented as Combined ROC Curves with Integrated Cutoff Distribution Curves and Novel Index

Values. *Diagnostics*. 2025;15(4):410. <https://doi.org/10.3390/diagnostics15040410> EDN: RVVGUV

16. Nagy I, Curik I, Nguyen AT, Farkas J, Kövér G. The importance of random effects in detecting purging of inbreeding depression: A model comparison in Pannon White rabbits. *Animal*. 2025;19(2):101412. <https://doi.org/10.1016/j.animal.2024.101412> EDN: YOKBLG

17. Groen J, De Haan BM, Overduin RJ, Haijer-Schreuder AB, Derks TG, Heiner-Fokkema MR. A machine learning model accurately identifies glycogen storage disease Ia patients based on plasma acylcarnitine profiles. *Orphanet Journal of Rare Diseases*. 2025; 20(1):15. <https://doi.org/10.1186/s13023-025-03537-2> EDN: GXCZCP

About the authors

Olga A. Saltykova, PhD in Physical and Mathematical Sciences, Associate Professor of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; eLIBRARY SPIN-code: 3969-6707; ORCID: 0000-0002-3880-6662; e-mail: saltykova-oa@rudn.ru

Vyacheslav D. Saushkin, Graduate student of the Department of Mechanics of Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198 Russian Federation; eLIBRARY SPIN-code: 1525-5653, ORCID: 0009-0007-2812-184X; e-mail: kingrailag@gmail.com

Сведения об авторах

Салтыкова Ольга Александровна, кандидат физико-математических наук, доцент кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-код: 3969-6707, ORCID: 0000-0002-3880-6662; e-mail: saltykova-oa@rudn.ru

Саушкин Вячеслав Дмитриевич, аспирант кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-code: 1525-5653, ORCID: 0009-0007-2812-184X; e-mail: kingrailag@gmail.com



DOI: 10.22363/2312-8143-2025-26-3-266-272

EDN: YICUJW

Научная статья / Research article

Генерация реалистичных изображений нефтегазовой инфраструктуры на космических снимках с использованием диффузионных моделей

В.К. Лобанов^{ID}, М.С. Кондрашина^{ID}✉, Ш.М. Гаджиев^{ID}, М.Ш. Сокибеков^{ID}

Российский университет дружбы народов, Москва, Российская Федерация

✉ 1132236536@rudn.ru

История статьи

Поступила в редакцию: 27 апреля 2025 г.

Доработана: 27 июня 2025 г.

Принята к публикации: 5 июля 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. В рамках исследования была изучена возможность применения методов машинного обучения, в частности генеративных моделей, для семантического редактирования космических снимков. Основное внимание уделено актуальной архитектуре на основе диффузионных моделей, способной генерировать целевые объекты непосредственно на спутниковых изображениях. Однако ввиду специфики выбранной предметной области — генерации реалистичных изображений объектов нефтегазовой инфраструктуры (таких как трубопроводы) были обнаружены существенные недостатки стандартной модели в части реализма и соответствия окружающему контексту. Для решения данной проблемы проводилось дообучение нейронной сети. Цель дообучения — улучшение качества визуализации проектных решений, связанных с трубопроводами. Предложен и детально описан методический подход к формированию специализированного обучающего набора данных. На основе реальных трасс трубопроводов в QGIS созданы пространственно привязанные векторные слои; сгенерирован набор тайлов космических снимков с точными аннотациями границ труб. Результаты экспериментального дообучения модели продемонстрировали значимое улучшение качества генерируемых изображений объектов нефтегазовой инфраструктуры на космических снимках по сравнению с показателями исходной, неадаптированной модели. Разработанная дообученная модель обеспечивает высокореалистичную генерацию трубопроводов, корректно интегрируя их в существующий ландшафт на снимке. Визуальное сравнение результатов до и после дообучения подтверждает устранение артефактов и достижение необходимого уровня детализации. Работа подтверждает эффективность подхода с формированием предметно-ориентированных датасетов и дообучением для решения специфических задач визуализации в ДЗЗ.

Ключевые слова: дистанционное зондирование Земли, нейронные сети, генеративные модели, машинное обучение, семантическое редактирование

Вклад авторов

Лобанов В.К. — общая концепция исследования, научное руководство; Кондрашина М.С. — написание текста; Гаджиев Ш.М. — написание изначального текста, визуализация; Сокибеков М.Ш. — написание текста. Все авторы ознакомлены с окончательной версией статьи и одобрили ее.

© Лобанов В.К., Кондрашина М.С., Гаджиев Ш.М., Сокибеков М.Ш., 2025



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License
<https://creativecommons.org/licenses/by-nc/4.0/legalcode>

Финансирование

Статья подготовлена при поддержке Министерства науки и высшего образования Российской Федерации в рамках выполнения государственного задания по соглашению № 075-03-2024-059 (FSSF-2024-0005).

Для цитирования

Лобанов В.К., Кондрашина М.С., Гаджиев Ш.М., Сокибеков М.Ш. Генерация реалистичных изображений нефтегазовой инфраструктуры на космических снимках с использованием диффузионных моделей // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 266–272. <http://doi.org/10.22363/2312-8143-2025-26-3-266-272>

Generating Realistic Images of Oil and Gas Infrastructure in Satellite Imagery Using Diffusion Models

Vasily K. Lobanov^{ID}, Mariia S. Kondrashina^{ID}✉,
Shamil M. Gadzhiev^{ID}, Maksad Sh. Sokibekov^{ID}

RUDN University, Moscow, Russian Federation

✉ 1132236536@rudn.ru

Article history

Received: April 27, 2025

Revised: June 27, 2025

Accepted: July 5, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. This study investigated the feasibility of applying machine learning methods, specifically generative models, for semantic editing of satellite imagery. The research focused on an architecture based on diffusion models capable of generating desirable objects directly on satellite images. However, significant shortcomings were identified in the standard model with regard to realism and relevance to the surrounding context, given the specific nature of the chosen subject area, namely the generation of realistic images of oil and gas infrastructure objects (such as pipelines). To address this limitation, fine-tuning of the neural network was performed. The objective of the fine-tuning was to enhance the quality of visualizing pipeline-related design solutions. A methodological approach for creating training dataset was proposed and described in detail. Based on actual pipeline routes, spatially referenced vector layers were created in QGIS, and a set of satellite image tiles with precise pipeline boundary annotations was generated. The results of the experimental fine-tuning demonstrated a significant improvement in the quality of generated images depicting oil and gas infrastructure objects in satellite imagery compared to the original, non-adapted model. The developed fine-tuned model enables highly realistic pipeline generation, effectively integrating them into the existing landscape within the image. Visual comparison of results before and after fine-tuning confirms the elimination of artifacts and the achievement of the required level of detail. This work demonstrates the effectiveness of the approach involving the creation of specific datasets and fine-tuning for solving specialized visualization tasks in remote sensing.

Keywords: earth remote sensing, neural network, generative models, machine learning, semantic editing

Authors' contribution

Lobanov V.K. — research concept, supervision; Kondrashina M.S. — writing; Gadzhiev Sh.M. — writing, visualization; Sokibekov M.Sh. — writing. All authors read and approved the final version of the article.

Funding

This paper has been supported by the Ministry of Science and Higher Education of the Russian Federation under Agreement No. FSSF-2024-0005.

For citation

Lobanov VK, Kondrashina MS, Gadzhiev ShM, Sokibekov MSh. Generating realistic images of oil and gas infrastructure in satellite imagery using diffusion models. *RUDN Journal of Engineering Research*. 2025;26(3):266–272. (In Russ.) <http://doi.org/10.22363/2312-8143-2025-26-3-266-272>

Введение

Использование космических снимков позволяет решать многие задачи. Поэтому разработка моделей и методов обработки изображений является чрезвычайно актуальной.

Цель исследования — оценка использования нейронных сетей для визуализации прокладки трубопроводов. Для решения поставленной нами задачи изучены возможности модели, предложенной авторами статьи “Tackling Few-Shot Segmentation in Remote Sensing via Inpainting Diffusion Model” [1].

Применение данной модели для прокладки трубопровода показало ее недостаточную эффективность. Для улучшения результатов использования модели провели дообучение на основе сформированного обучающего набора.

Актуальность подхода связана с применением современных нейронных сетей и решаемой проблемы визуализации нефтегазовой инфраструктуры на космических снимках.

1. Методы

1.1. Архитектура нейронной сети

Проанализируем принцип работы модели, предложенной в [1] и состоящей из нижеперечисленных «блоков».

Stable Diffusion — это генеративная диффузионная модель, предназначенная для создания высококачественных изображений из текстовых описаний или на основе других изображений. Модель работает с пространством скрытых признаков, за счет этого способна достигать высокой эффективности при работе с изображениями. Обучение модели происходит на задаче «обратного шума» — она учится постепенно восстанавливать изображение из шума. При генерации *Stable Diffusion* «движется в обратном порядке» от случайного шума к содержательному изображению [2; 3].

Основные компоненты *Stable Diffusion*:

1. **Автокодировщик** (VAE — Variational Autoencoder) — используется для перевода изображений в пространство признаков и обратно

и состоит из кодировщика (encoder), который сжимает изображение до латентного представления и декодировщика (decoder), восстанавливающего изображение из полученного кодировщиком представления [4].

Использование автокодировщика позволяет значительно ускорить обучение и генерацию по сравнению с работой с обычными пиксельными изображениями за счет снижения размерности данных и извлечения признаков.

2. **UNet** — это основной модуль, обрабатывающий скрытое пространство признаков.

Архитектура UNet: симметричная сеть с блоками downsampling (понижающей дискретизации) и upsampling (повышающей дискретизации) [5].

В каждом блоке используются следующие составляющие: остаточные связи (residual), внимание (attention) и нормализация (group normalization).

На вход модуля поступает зашумлённое пространство признаков, время шага в процессе диффузии (timestep) и текстовая подсказка (через cross-attention).

3. **Text Encoder** (CLIP Text Encoder) — разработанный OpenAI текстовый кодировщик CLIP (Contrastive Language — Image Pretraining) (ViT-B/32), преобразующий текстовую подсказку в вектор признаков. Эти признаки используются в UNet через cross-attention механизмы, чтобы направлять генерацию изображения [6].

4. **Scheduler** (DDIM/DDPM) — управляет процессом добавления и удаления шума. Во время генерации работает в режиме «обратного процесса»: начиная со случайного шума, модель постепенно приближает его к изображению.

Принцип работы этого метода заключается в следующем:

1. Текст → Вектор признаков: текст обрабатывается кодировщиком CLIP.

2. Латентное пространство: генерация начинается со случайного шума в латентном пространстве.

3. Процесс диффузии: UNet итеративно очищает шум, направляясь вектором признаков текста.

4. VAE Decoder: финальное латентное представление декодируется обратно в изображение.

RemoteCLIP — использовалась для обработки спутниковых и аэрофотоснимков (дистанционного зондирования) [7] и представляет собой адаптированную версию CLIP [6].

Модель обучается сопоставлять спутниковые изображения с текстовыми описаниями. Изображения и тексты кодируются в общее признаковое пространство, где близкие по смыслу пары находятся рядом.

RemoteCLIP содержит следующие основные компоненты:

1. Кодировщик изображения (image encoder) обычно используют ResNet [8] или Vision Transformer (ViT) [9]. Кодировщик преобразует изображение в векторные представления, с целью уменьшения объема данных для передачи используется квантование или компрессия.

2. Текстовый кодировщик (Text Encoder) (на сервере / в облаке) — использует трансформер (Transformer) для получения вектора признаков текстовой подсказки.

3. Коммуникационный интерфейс передает векторы признаков от клиента к серверу. Важными задачами являются сжатие, безопасность и стабильность передачи.

4. Fusion Module (на сервере) — сопоставляет визуальный и текстовый вектор признаков, вычисляя косинусное сходство.

Взаимодействие: Stable Diffusion + RemoteCLIP. На первом этапе Stable Diffusion используется в режиме дорисовки (inpainting) для заполнения области изображения (с заданной маской) синтетическим объектом.

Вместо текстового запроса подается визуальный образец (изображение с примером объекта нужного класса).

На следующем этапе RemoteCLIP применяется в качестве кодировщика изображения, чтобы получить вектор признаков объекта из референсного изображения.

Полученные векторы признаков передаются в Stable Diffusion как условие генерации, т.е. модель понимает, какой объект необходимо «нарисовать» в области маски.

1.2. Формирование обучающего набора

По маршрутам существующих трубопроводов в QGIS (свободная бесплатная географическая информационная система с открытым кодом) были построены векторные слои. Затем для формирования обучающей выборки для маршрутов трубопроводов были получены космические снимки и векторные данные с точным расположением труб, которые использовались для дообучения модели.

Формирование обучающего набора начинается с подготовки слоев в QGIS и преобразования координат. Загружается векторный линейный слой (маршрут трубопровода) и растровая подложка, после чего определяется необходимость перехода между системами координат. Если требуется, то все линейные объекты из слоя преобразуются к системе координат подложки.

Далее выполняется создание фрагментов карты (тайлов) — квадратных зон с центрированием вдоль линейного объекта. Количество и расположение рассчитывается с учетом процента перекрытия соседних тайлов. Каждый полученный участок добавляется в память в виде полигона с уникальным идентификатором.

После этого для каждого полученного полигона проверяется, пересекает ли его хотя бы одна из трубопроводных линий. Если пересечение обнаружено, вычисляются прямоугольные границы (bbox) в пиксельных координатах относительно тайла. Координаты полигонов bbox сохраняются в текстовых файлах в формате YOLO для дальнейшего использования в задаче обнаружения объектов.

На этапе сохранения для каждого фрагмента карты формируется временный файл GeoTIFF в пределах границ тайла, который затем преобразуется в формат JPEG с помощью инструментов GDAL с последующим удалением исходного файла. Файл с текстовыми координатами bbox сохраняется под тем же названием, что и изображение.

Полученный набор для дообучения имеет следующую рекомендованную структуру [10], представленную на рис. 1.




Рис. 1. Структура обучающего набора данных:
bbox — вектор объекта;
images — соответствующее изображение
Источник: выполнено Ш.М. Гаджиевым

Figure 1. Training dataset structure:
bbox — object bounding box coordinates;
images — corresponding image
Source: by Sh.M. Gadzhiev

2. Результаты и обсуждение

2.1. Дообучение

Дообучение требовалось провести из-за отсутствия в начальном обучающем наборе класса с трубами. Следовательно, модель была не способна их генерировать. Для генерации необходимы изначально изображение, маска области и непосредственно объект, который мы будем вставлять. При подаче в качестве референса участка трубопровода созданная труба выглядела как белая линия (рис. 2, а, б).

Во время дообучения можно заметить, как с каждой эпохой модель справлялась с задачей генерации труб лучше и лучше. В качестве метрики была выбрана сглаженная ошибка валидации (экспоненциальное среднее). Приведем сравнение величины на 5-й и 9-й итерации, где значение уменьшилось с 0,86 до 0,77 (рис. 3 и 4).

После дообучения модели на основе обучающей выборки с учетом вектора координат трубы на новый класс — «трубы» модель стала лучше встраивать трубопровод в космический снимок. Результат представлен на рис. 5.




Рис. 2. Применение оригинальной модели для генерации трубопровода:
а — подаваемые параметры; б — полученный результат
Источник: выполнено Ш.М. Гаджиевым

Figure 2. Application of the original model for pipeline generation:
а — input parameters; б — obtained result
Source: by Sh.M. Gadzhiev

```
Average Peak memory 22746.30MiB
Epoch 5, global step 1949: val/loss_simple_ema reached 0.08618 (best 0.08618),
Epoch 6: 8% 40/474 [00:24<04:22, 1.65it/s, loss=0.153, v_num=0, train/loss_
Data shape for DDIM sampling is (1, 4, 64, 64), eta 1.0
```

Рис. 3. Значение потерь на 5-й эпохе
Источник: выполнено Ш.М. Гаджиевым

Figure 3. Loss value at epoch 5
Source: by Sh.M. Gadzhiev

```
Average Peak memory 22747.53MiB
Epoch 9, global step 3249: val/loss_simple_ema reached 0.07785 (best 0.07785), saving model to "/
Epoch 9: 100% 474/474 [06:13<00:00, 1.27it/s, loss=0.11, v num=0, train/loss simple step=0.0445,
```

Рис. 4. Значение потерь на 9-й эпохе
Источник: выполнено Ш.М. Гаджиевым

Figure 4. Loss value at epoch 9
Source: by Sh.M. Gadzhiev




Рис. 5. Применение дообученной модели для генерации трубопровода:
а — подаваемые параметры; б — полученный результат
Источник: выполнено Ш.М. Гаджиевым

Figure 5. Application of the fine-tuned model for pipeline generation:
a — input parameters; б — obtained result
Source: by Sh.M. Gadzhiev

Заключение

В исследовании рассматривалась проблема визуализации объектов нефтегазовой индустрии на снимках дистанционного зондирования Земли. В ходе работы был изучен и доработан подход на основе диффузионных моделей. Для улучшения результатов изучаемой модели было осуществлено дообучение на основе сформированного набора данных. После нашего дообучения модели повысилось качество снимков, полученных в ходе генерации реалистичных изображений нефтегазовой инфраструктуры на космических снимках по сравнению с моделью, в референсной статье.

Список литературы / References

1. Immanuel SA, Cho W, Heo J, Kwon D. Tackling Few-Shot Segmentation in Remote Sensing via Inpainting Diffusion Model. *ICLR 2025 Machine Learning for Remote Sensing (ML4RS) Workshop*. 2025. <https://doi.org/10.48550/arXiv.2503.03785>
2. Rombach R, Blattmann A, Lorenz D, Esser P, Ommer B. High-Resolution Image Synthesis with Latent

- Diffusion Models. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR); 2022 June 18–24; New Orleans, LA, USA. *IEEE*. 2022:10674–10685. <https://doi.org/10.1109/CVPR52688.2022.01042>
3. Panboonyuen T, Charoenphon C, Satirapod C. SatDiff: A Stable Diffusion Framework for Inpainting Very High-Resolution Satellite Imagery. *IEEE Access*. 2025;13:51617–51631. <https://doi.org/10.1109/ACCESS.2025.3551782>
4. Kingma DP, Welling M. Auto-Encoding Variational Bayes (Version 11). *International Conference on Learning Representations (ICLR)*. 2014. <https://doi.org/10.48550/ARXIV.1312.6114>
5. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention MICCAI*. 2015;9351:234–241. <https://doi.org/10.48550/arXiv.1505.04597>
6. Radford A, Kim JW, Hallacy C, Ramesh A, Goh G, Agarwal S, et al. Learning Transferable Visual Models from Natural Language Supervision. *Proceedings of the 38th International Conference on Machine Learning, PMLR*. 2021;139:8748–8763. <https://doi.org/10.48550/ARXIV.2103.00020>
7. Liu F, Chen D, Guan Z, Zhou X, Zhu J, Ye Q, et al. RemoteCLIP: A Vision Language Foundation Model for Remote Sensing. *IEEE Transactions on Geoscience*

and Remote Sensing. 2024;62:1–16. <https://doi.org/10.1109/TGRS.2024.3390838>

8. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016; 770–778. <https://doi.org/10.48550/ARXIV.1512.03385>

9. Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, et al. An Image is Worth

16×16 Words: Transformers for Image Recognition at Scale. *International Conference on Learning Representations (ICLR 2021)*. <https://doi.org/10.48550/ARXIV.2010.11929>

10. Immanuel SA, Cho W, Heo J, Kwon D. Tackling Few-Shot Segmentation in Remote Sensing via Inpainting Diffusion Model. *ICLR 2025 Machine Learning for Remote Sensing (ML4RS) Workshop*. 2025. <https://doi.org/10.48550/arXiv.2503.03785>

Сведения об авторах

Лобанов Василий Константинович, старший преподаватель кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-код: 7266-5340; ORCID: 0000-0001-8163-9663; e-mail: lobanov_vk@pfur.ru

Кондрашина Мария Сергеевна, магистрант кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0009-0008-8526-9143; e-mail: 1132236536@rudn.ru

Гаджиев Шамиль Магомедминович, магистрант кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0009-0006-1570-4133; e-mail: 1132236511@rudn.ru

Сокибеков Максад Ширинбекович, магистрант кафедры архитектура, реставрация и дизайн, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0009-0009-0261-7374; e-mail: 1032185455@rudn.ru

About the authors

Vasily K. Lobanov, Senior Lecturer of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; eLIBRARY SPIN-code: 7266-5340; ORCID: 0000-0001-8163-9663; e-mail: lobanov_vk@pfur.ru

Mariia S. Kondrashina, Master student of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0009-0008-8526-9143; e-mail: 1132236536@rudn.ru

Shamil M. Gadzhiev, Master student of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0009-0006-1570-4133; e-mail: 1132236511@rudn.ru

Maksad Sh. Sokibekov, Master student of the Department of Architecture, Restoration and Design, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0009-0009-0261-7374; e-mail: 1032185455@rudn.ru



DOI: 10.22363/2312-8143-2025-26-3-273-287

EDN: YOXOFH

Research article / Научная статья

Comparative Performance of Machine Learning Classifiers in Detecting Vibration Anomalies in Industrial Power Systems

Al-Tekreeti Watban Khalid Fahmi^{ID}, Kazem Reza Kashyzadeh^{ID✉}, Siamak Ghorbani^{ID},
Siamak Ghorbani^{ID}, Sergei A. Kupreev^{ID}, Oleg E. Samusenko^{ID}

RUDN University, Moscow, Russian Federation

✉ reza-kashi-zade-ka@rudn.ru

Article history

Received: March 13, 2025

Revised: April 30, 2025

Accepted: May 15, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Data Availability Statement:

The datasets can be made available upon request from the authors.

Abstract. This study examines methodologies for detecting abnormalities in Combined Cycle Power Plants (CCPPs) through application of vibration signal analysis and machine learning algorithms. Models' performances were evaluated using different key metrics. The results indicated that the Random Forest classifier, particularly in combination with ECPT data, exhibited superior performance, achieving perfect scores across all metrics. It highlights the robustness of the Random Forest algorithm when applied to ECPT data, making it the most effective approach for vibration anomaly detection. The K-NN classifier demonstrated satisfactory performance when applied to AS and BTT data, attaining accuracy scores of 0.49 and 0.52, respectively; however, it exhibited limitations in handling diverse data distributions, as reflected in its lower accuracy of 0.44 with LDV data. Both GBM and SVM performed suboptimal, with GBM achieving a maximum accuracy of 0.52 with AS data, while SVM attained the highest accuracy of 0.49 with the same technique. Findings underscore the critical importance of selecting an appropriate combination of machine learning models and vibration measurement techniques to enhance the accuracy of anomaly detection. Eventually, the Random Forest algorithm is well suited for complex datasets with varied patterns, while K-NN may serve as an efficient alternative for simpler, more uniform data.

Keywords: Vibration data, Fault diagnosis, Machine learning classification, Condition monitoring, Combined cycle power plants, CCPP, Predictive maintenance

Authors' contribution

Fahmi A.T.W.K. — methodology, software, validation, writing-original draft preparation; *Reza Kashyzadeh K.* — methodology, formal analysis, investigation, writing-review and editing, supervision, project administration; *Ghorbani S.* — methodology, investigation, writing-original draft preparation; *Kupreev S.A.*, *Samusenko O.E.* — writing and editing. All authors read and approved the final version of the article.

For citation

Fahmi ATWK, Reza Kashyzadeh K, Ghorbani S, Kupreev SA, Samusenko OE. Comparative performance of machine learning classifiers in detecting vibration anomalies in industrial power systems. *RUDN Journal of Engineering Research*. 2025; 26(3):273–287. <http://doi.org/10.22363/2312-8143-2025-26-3-273-287>



Сравнительная эффективность классификаторов машинного обучения при обнаружении аномалий вибрации в промышленных энергосистемах

А.Т.В.Х. Фахми[✉], К. Реза Каши Заде[✉], С. Горбани[✉],
С.А. Купреев[✉], О.Е. Самусенко[✉]

Российский университет дружбы народов, Москва, Российская Федерация

✉ reza-kashi-zade-ka@rudn.ru

История статьи

Поступила в редакцию: 13 марта 2025 г.

Доработана: 30 апреля 2025 г.

Принята к публикации: 15 мая 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Заявление о доступности данных:

Данные могут быть предоставлены по запросу авторов.

Аннотация. Изучены методологии обнаружения отклонений в электростанциях комбинированного цикла посредством применения анализа сигналов вибрации и алгоритмов машинного обучения. Результаты показали, что метод случайного леса, особенно в сочетании с данными вихрековых датчиков приближения, продемонстрировал превосходную эффективность, достигнув идеальных результатов по всем показателям. Это подчеркивает надежность алгоритма случайного леса при применении к данным вихрековых датчиков приближения, что делает его наиболее эффективным подходом для обнаружения аномалий вибрации. Классификатор K-NN продемонстрировал удовлетворительную эффективность при применении к данным датчиков ускорения и датчики синхронизации кромки лопатки, достигнув показателей точности 0,49 и 0,52 соответственно; однако он продемонстрировал ограничения при обработке различных распределений данных, что отражено в его более низкой точности 0,44 с данными лазерных доплеровских виброметров. Машина для повышения градиента и метод опорных векторов показали неоптимальные результаты, причем машина для повышения градиента достигла максимальной точности 0,52 с данными датчиков ускорения, в то время как метод опорных векторов достиг наивысшей точности 0,49 с той же методикой. Результаты подчеркивают критическую важность выбора подходящей комбинации моделей машинного обучения и методов измерения вибрации для повышения точности обнаружения аномалий. В итоге алгоритм случайного леса хорошо подходит для сложных наборов данных с разнообразными моделями, в то время как K-NN может служить эффективной альтернативой для более простых и однородных данных.

Ключевые слова: данные о вибрации, диагностика неисправностей, классификация машинного обучения, мониторинг состояния, электростанции комбинированного цикла, ССРР, прогностическое обслуживание

Вклад авторов

Фахми А.Т.В.Х. — методология, программное обеспечение, проверка, написание — подготовка первоначального проекта; Реза Каши Заде К. — методология, формальный анализ, проведение исследования, написание — рецензирование и редактирование, руководство, администрирование проекта; Горбани С. — методология, проведение исследования, написание и подготовка первоначального черновика; Купреев С.А., Самусенко О.Е. — написание и редактирование текста. Все авторы ознакомлены с окончательной версией статьи и одобрили ее.

Для цитирования

Fahmi A.T.W.K., Reza Kashyzadeh K., Ghorbani S., Kupreev S.A., Samusenko O.E. Comparative performance of machine learning classifiers in detecting vibration anomalies in industrial power systems // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 273–287. <http://doi.org/10.22363/2312-8143-2025-26-3-273-287>

Introduction

Vibration analysis is a crucial aspect of condition monitoring in industries that rely on rotating equipment, such as petrochemical plants and power plants. In CCPPs, which utilize both gas and steam turbines, continuous monitoring and evaluation of vibration signals are essential to ensuring reliability and efficiency in power generation. Vibration analysis serves as an effective method for detecting early signs of mechanical failures, such as rotary imbalance, coupling misalignment, and component wear, before they lead to costly downtime, reduced efficiency, or catastrophic equipment failure [1; 2]. In a CCPPs, vibration monitoring is particularly critical for primary energy-generating machinery, such as gas turbines, where even minor faults like speed fluctuations, excessive vibration, or timing irregularities, can

result in significant efficiency losses, increased fuel consumption, and unplanned shutdowns, ultimately affecting overall plant performance [3; 4]. Figure 1 presents various damages that occurred in the gas turbine of the Kirkuk power plant located in Iraq.

Multiple factors contribute to vibrations in gas turbines and other rotating equipment. Common issues include shaft unbalance, critical speed occurrence, rubbing, and shorted turns off. Each of these problems can be detected using specialized vibration analysis techniques [5; 6]. For example, shaft unbalance, a leading cause of high-amplitude vibrations, adversely affects bearings, shafts, and other rotating components, leading to increased maintenance costs and reduced operational efficiency. Figure 2 shows bearing damage due to misalignment in a gas turbine of the Kirkuk power plant located in Iraq.




Figure 1. Gas turbine damages in the Kirkuk power plant due to the occurrence of vibrations caused by: *a* and *b* — steam flow fluctuations; *c* — rubbing

Source: by Al-T.W.K. Fahmi




Figure 2. Bearing damage due to the misalignment in a gas turbine of the Kirkuk power plant located in Iraq

Source: by Al-T.W.K. Fahmi

Studies suggest that correcting unbalance and misalignment issues can greatly reduce power consumption in industrial machinery [7]. Similarly, critical speed resonance occurs when a machine operates at or near its natural frequency, causing excessive wear and potential failure. Preventative maintenance techniques, such as short-time Fourier transform (STFT), are often employed to detect critical speed issues during machine start-up and shutdown phases [8].

Various condition monitoring techniques are used to acquire the dynamic signatures of these mechanical defects. These include Eddy Current Proximity Transducers (ECPT), Accelerometer Sensors (AS), Blade Tip Timing (BTT), Laser Doppler Vibrometers (LDV), and Strain Gauges (SG), each offering unique advantages and limitations. ECPT, for instance, provides highly accurate displacement measurements for high-speed equipment but requires time consuming calibration [9]. Accelerometers are versatile and capable of measuring a wide range of vibration frequencies, though they are susceptible to electromagnetic interference [10]. BTT is a non-intrusive technique that provides high-resolution data on blade vibrations, but it is limited to blade tip measurements [11]. LDV is a highly sensitive contactless measurement method capable of detecting minute oscillations, though it requires sophisticated and costly equipment [12]. Finally, SGs are effective in measuring strain in structural components but require precise calibration and are influenced by temperature variations [13].

Recent advancements in machine learning (ML) techniques have introduced powerful new approaches to vibration data analysis and faults in complex industrial systems diagnostics. ML models such as Random Forest (RF), Gradient Boosting Machine (GBM), Support Vector Machine (SVM), and K-Nearest Neighbors (K-NN) have been widely used for processing large datasets, detecting abnormal patterns, and classifying vibration signals [14]. RF, an ensemble-based decision tree classifier, is particularly effective in handling high-dimensional and noisy data, making it well-suited for ECPT and AS datasets. GBM, another ensemble

method, sequentially improves predictions by minimizing errors and is particularly useful for structured datasets, such as those generated by accelerometers and strain gauges [15]. SVM, a strong binary classifier, excels at finding optimal hyperplanes for separating different vibration patterns, though its performance is highly dependent on data structure and dimensionality [16]. K-NN, a distance-based classifier, operates under the assumption that a data point's classification is determined by its nearest neighbors. Despite its simplicity, K-NN performs well when dealing with densely clustered vibration data, such as those obtained from high-frequency techniques [17]. Its straightforward implementation and low computational requirements make it particularly useful for real-time industrial applications where processing power is limited. Given its efficiency, K-NN serves as a useful benchmark for comparing more complex models in vibration classification.

This study aims to evaluate and compare the effectiveness of RF, GBM, SVM, and K-NN classifiers in analyzing synthetic vibration data generated from five monitoring techniques: ECPT, AS, BTT, LDV, and SG. The synthetic data were designed to simulate real-world conditions by varying key parameters such as vibration frequency, amplitude, and noise levels, allowing for comprehensive testing across multiple operational scenarios. To enhance model performance, preprocessing techniques such as data labeling (normal vs. abnormal) and outlier removal were applied. The performance of each classifier was assessed using standard evaluation metrics, including accuracy, precision, recall, F1-score, and the area under the receiver operating characteristic (ROC AUC) curve.

This study is guided by the following research questions:

1. Which machine learning classifier demonstrates the highest accuracy in detecting vibration anomalies across different monitoring techniques?
2. How do variations in vibration measurement techniques impact classifier performance?
3. Can a specific combination of machine learning models and monitoring techniques optimize vibration anomaly detection in CCPPs?

By addressing these questions, this research seeks to provide valuable insights into the integration of machine learning with traditional vibration analysis techniques, ultimately contributing to more efficient and predictive maintenance strategies in industrial settings [18].

1. A brief Description of the Most Important Vibration Measurement Techniques in Industry

The following is a brief description of the mechanism of the techniques used in this research to measure vibration in a gas turbine:

1.1. Eddy Current Proximity Transducers (ECPT)

ECPTs are widely used in power plants, particularly for monitoring the movement of the rotating machinery by detecting changes in proximity to an electromagnetic field. These sensors are preferred in high-speed applications and testing environments due to their reliability.

Research indicates that ECPTs can measure even the smallest displacement changes, making them suitable for tracking critical components such as turbine shafts and bearings [12]. However, ECPTs have some limitations: they can only sense movement in one direction, their calibration process is highly sensitive, time-consuming, and requires specialized equipment [19].

1.2. Accelerometer Sensors (AS)

Accelerometers are commonly used for vibration monitoring due to their high versatility and responsiveness across a wide frequency range. They operate based on a mass-spring system, generating an electrical signal proportional to acceleration, which is then analyzed to assess vibration characteristics. These devices are widely applied in power plants, particularly for monitoring turbines and evaluating structural integrity¹.

However, accelerometers are susceptible to external vibrations and electromagnetic noise, which can reduce measurement accuracy and necessitate frequent recalibration².

1.3. Blade Tip Timing (BTT)

BTT is an intrusive method commonly used to detect turbine blade vibrations in combined cycle power plants (CCPPs). It employs optical or microwave sensors placed around the rotor to detect the timing of blade tip passages. Research has shown that BTT can identify both high- and low-frequency vibrations without requiring any modifications to the turbine [11]. For example, Zhang et al. developed a microwave-based BTT system in which a patch antenna probe transmits and receives microwave signals reflected from the turbine blades, providing highly accurate measurements of blade dynamics [17].

1.4. Laser Doppler Vibrometers (LDV)

Laser Doppler Vibrometers (LDVs) are a contactless and a highly accurate method for measuring small vibrations using laser beams. They operate by detecting variations in the frequency of laser light reflected from a vibrating surface, enabling real-time observation of rotating equipment. A key advantage of LDVs is their high sensitivity and accuracy, making them suitable for detecting even the smallest vibrations [20]. However, their high cost and the complex structures required for implementing control algorithms may limit their use in large-scale industrial applications. Recent studies have aimed to improve the applicability of LDVs by enhancing signal detection for both low-frequency and high-frequency vibrations [21].

1.5. Strain Gauges (SG)

Strain gauges record distortions caused by strain or vibration by measuring variations in the electrical resistance of a small metal strip bonded

¹ *Accelerometer specifications: deciphering an accelerometer's datasheet*. Available from: <https://www.scribd.com/document/650160365/Accelerometer-Specifications-Deciphering-an-Accelerometer-s-Datasheet> (accessed: 01.03.2025).

² *Most Common Myths about Accelerometers and Frequency Range*. Available from: <https://adash.com/articles/myths-accelerometers-frequency-range/> (accessed: 01.03.2025).

to a structure. They are particularly useful for monitoring large frameworks and support structures in power plants, as well as detecting structural distortions over time [13]. However, strain gauges typically have a low measurement range and can be affected by temperature changes. Therefore, these sensors require precise calibration for accurate strain measurements. Recent developments in strain gauge technology aim to improve temperature compensation and enhance accuracy in harsh environments, making them more reliable for structural health monitoring throughout a structure's lifecycle³.

2. Machine Learning Algorithms in Vibration Analysis

Machine learning methodologies have significantly improved the diagnosis and prediction of vibrations in complex industrial systems. Many studies highlight the advantages of using machine learning for fault detection, particularly in CCPs, where early signs of equipment degradation can greatly impact plant reliability. The following is a brief description of the machine learning algorithms used in this research for the purpose of vibration analysis:

2.1. Random Forest (RF)

Random Forest is a widely used ensemble learning model known for its stability and ability to handle large numbers of features in vibration signal classification. It constructs multiple decision trees during training and integrates their results to improve classification efficiency. Previous research has demonstrated that the Random Forest algorithm performs well in detecting abnormal patterns from ECPT and accelerometer sensor data due to its low susceptibility to overfitting and its strong interpretability in large datasets with many variables. For example, one study showed that an RF model trained with synthetic vibration data for ECPT achieved 100% accuracy in exact measurement [14].

2.2. Gradient Boosting Machine (GBM)

GBM is an ensemble learning method composed of sequentially assembled decision trees, focusing on error minimization at each stage. This makes it particularly effective for the discrete datasets commonly used in vibration analysis. As misclassified cases are iteratively added to improve the model, GBM enhances its ability to identify minute patterns, such as those seen in accelerometer and strain gauge data. Studies have shown that GBM efficiently uncovers relationships within data and improves outlier detection by refining weak learners at each iteration step. In one study, GBM achieved an accuracy of 0.52 on AS data, demonstrating its effectiveness in classifying structured sensor data.

2.3. Support Vector Machine (SVM)

SVM is a well-known classification algorithm that selects the optimal hyperplane to separate data points. It is particularly effective in cases where binary classification is essential. Research has shown that SVM performs well in detecting vibration abnormalities, especially when using accelerometer and blade tip timing (BTT) data [22]. However, its performance depends on the dataset structure and its time complexity increases with large datasets, which can hinder real-time applications in certain CCP scenarios [16].

2.4. K-Nearest Neighbors (K-NN)

K-NN is a simple, instance-based learning model that classifies data points based on their similarity to neighboring data. Its simplicity makes it an ideal choice in scenarios where computational resources are limited, but fast classification is required. Studies indicate that K-NN performs well in density-based functions, such as accelerometer analysis and blade tip timing data, particularly when dealing with closely grouped datasets [18]. In one study, K-NN achieved accuracy rates of

³ *Characteristics of a Strain Gauge Sensor*. Bestech Australia. Available from: <https://www.bestech.com.au/blogs/characteristics-of-a-strain-gauge-sensor/> (accessed: 01.03.2025).

0.49 and 0.52 for AS and BTT data accordingly, respectively, highlighting its effectiveness as a lightweight, distance-based classifier in specific vibration monitoring scenarios [19].

Previous research confirms that combining vibration measurement techniques with fault classification algorithms significantly enhances fault diagnosis in CCPPs. Highly sensitive methods, such as ECPT and accelerometers, and precise non-contact methods, such as BTT and LDV, provide reliable data for analysis. The use of machine learning models — particularly ensemble methods like RF and GBM — has improved classification accuracy in vibration monitoring. While basic algorithms like K-NN are useful in limited contexts, real-time anomaly detection often requires balancing simplicity with execution speed. This review provides the foundation for the comparative analysis conducted in this study, emphasizing the importance of selecting appropriate machine learning models and sensor techniques based on the specific needs of CCPP vibration monitoring.

3. Methodology and Its Implementation

The methodology of this study consists of synthetic data generation, data preprocessing, machine learning model training, and performance evaluation. Each step is systematically designed to evaluate the effectiveness of various vibration signals analysis methods used in CCPPs for monitoring and classifying abnormalities.

Step I. Synthetic Data Generation

To simulate real-world vibration monitoring scenarios, synthetic vibration data was generated for five commonly used techniques: Eddy Current Proximity Transducers (ECPT), Accelerometer Sensors (AS), Blade Tip Timing (BTT), Laser Doppler Vibrometers (LDV), and Strain Gauges (SG). The data for each technique was modeled with varying assumptions regarding frequency, amplitude, and noise level to better represent the operating conditions of CCPP systems.

The synthetic data generation process is as follows:

- *Frequency (Hz)*: Represents the average number of times per week that each technique is used. For instance, ECPT was modeled with a frequency of 1,000,000 Hz, while BTT was set at 100 Hz to reflect their distinct operational characteristics.

- *Amplitude*: Corresponds to the vibration signal strength, set to approximate real-world values. For example, ECPT was assigned an amplitude of 100, while LDV was set at 2.5.

- *Noise Level*: Gaussian noise was added to the data to simulate environmental interference. For instance, a noise level of 1.0 was applied to ECPT data, whereas SG data had a noise level of 0.5, reflecting different levels of noise tolerance across techniques.

The generated dataset included labeled data for each technique, where a subset was designated as ‘normal’ and the rest as ‘abnormal’ to maintain a binary classification approach. Due to the L and N nature of the synthetic data, testing, and evaluation of the model become flexible without negative influence from real data conditions.

Step II. Data Preprocessing

To ensure the quality and suitability of the generated dataset for machine learning analysis, data preprocessing was performed. This process involved two key steps:

- *Labeling*: Each dataset was categorized as “normal” or “abnormal” to establish a binary classification problem. The “normal” label represents typical operational behavior, while the “abnormal” label indicates deviations from expected behavior that could signal faults or potential issues in CCPP machinery.

- *Outlier Removal and Clipping*: Outliers were identified and clipped within a specified amplitude range (e.g., between –3 and 3) to improve model training accuracy. This step minimizes the impact of extreme values and enhances the robustness of classifiers by focusing the model on more typical operating conditions.

After preprocessing, the data was split into training (80%) and testing (20%) sets to ensure a reliable and balanced evaluation of model performance.

Step III. Machine Learning Models

Four classifiers were selected for model training, testing, and feature selection, each chosen for its ability to handle high-dimensional data and diverse feature patterns. The selected models include Random Forest (RF), Gradient Boosting Machine (GBM), Support Vector Machine (SVM), and K-Nearest Neighbors (K-NN). The selection aimed to compare different classifier types, including ensemble, distance-based, and linear models.

▪ *Random Forest (RF)*: A machine learning technique that constructs multiple decision trees and aggregates their outputs to improve the final prediction. RF is highly effective for handling high-dimensional and noisy data, making it particularly suitable for analyzing complex vibration patterns recorded in ECPT and AS data. To balance accuracy and prevent overfitting, the RF model was trained with 100 trees and a maximum depth of 10. The details of the algorithm are as follows:

Algorithm 1. Anomaly Detection with Random Forest (RF)

- 1: **Input**: Vibration monitoring dataset **X** with features and labels, where **X** is split into training and test sets.
- 2: **Output**: Trained **Random Forest** model, Anomaly classification results.
- 3: **Procedure** **TRAIN_RF_MODEL(X)**
- 4: **Preprocess** dataset **X** (normalization and missing value handling).
- 5: **Train** the Random Forest model using the training set.
- 6: **Evaluate** the model on the test set.
- 7: **Generate** accuracy and classification reports.
- 8: **Save** the trained model for anomaly detection.

9: End Procedure

▪ *Gradient Boosting Machine (GBM)*: A machine learning method for constructing an ensemble by training a series of models sequentially while minimizing generalization error. GBM was chosen because it is well suited for structured data such as the vibrations from AS and SG. Specifically, for the GBM model, the learning rate was set to 0.1, and the maximum depth was set to 5 to achieve optimal evaluation results while minimizing computational time. The details of the algorithm are as follows:

Algorithm 2. Anomaly Detection with Gradient Boosting Machine (GBM)

- 1: **Input**: Vibration monitoring dataset **X** with features and labels, where **X** is split into training and test sets.
- 2: **Output**: Trained **GBM** model, Anomaly classification results.
- 3: **Procedure** **TRAIN_GBM_MODEL(X)**
- 4: **Preprocess** dataset **X** (feature scaling and outlier removal).
- 5: **Initialize** GBM with chosen hyper parameters.
- 6: **Train** the GBM model using the training set.
- 7: **Validate** performance on the test set.
- 8: **Generate** precision and recall metrics.
- 9: **Save** the trained model for anomaly detection.

10: End Procedure

▪ *Support Vector Machine (SVM)*: A powerful binary classification algorithm that identifies the optimal hyperplane for separating classes, making it ideal for datasets with well-defined boundaries. SVM was applied to analyze the BTT and LDV datasets due to its strong performance in binary classification tasks. A linear kernel was chosen after initial experiments indicated that it provided the best balance between speed and accuracy. The details of the algorithm are as follows:

Algorithm 3. Anomaly Detection with Support Vector Machine (SVM)

- 1: **Input**: Vibration monitoring dataset **X** with features and labels, where **X** is split into training and test sets.
- 2: **Output**: Trained **SVM** model, Anomaly classification results.
- 3: **Procedure** **TRAIN_SVM_MODEL(X)**
- 4: **Standardize** dataset **X** (scale features to have zero mean and unit variance).
- 5: **Choose** the appropriate **kernel** type (e.g., linear, radial basis function (RBF)) based on dataset characteristics.
- 6: **Train** the SVM model using the training set, optimizing for the **margin** that separates data points.
- 7: **Validate** model performance on the test set using **accuracy**, **precision**, and **recall**.
- 8: **Tune** hyper parameters (e.g., **C**, **gamma**) to improve performance if necessary.
- 9: **Save** the trained SVM model for anomaly detection.

10: End Procedure

▪ *K-Nearest Neighbors (K-NN)*: A distance-based classifier that assigns labels to data points based on the majority label of their nearest neighbors, providing simplicity and interpretability.

K-NN was particularly effective for datasets with densely clustered points, such as AS and BTT. The model was implemented with `n_neighbors=5`, as this configuration was found to optimize classification accuracy while minimizing computational load. The details of the algorithm are as follows:

Algorithm 4. Anomaly Detection with K Nearest Neighbors (K-NN)

1: **Input:** Vibration monitoring dataset **X** with features and labels, where **X** is split into training and test sets.
 2: **Output:** Trained K-NN model, Anomaly classification results.
 3: **Procedure** `TRAIN_KNN_MODEL(X)`
 4: **Standardize** dataset **X** (normalize features to a common scale).
 5: **Choose** the value of **K** based on cross-validation.
 6: **Train** K-NN model on the training set.
 7: **Evaluate** K-NN model accuracy on the test set.
 8: **Compute** F1-score and confusion matrix.
 9: **Save** trained model for anomaly detection.

10: End Procedure

Each model was trained on the preprocessed synthetic data to distinguish between “normal” and “abnormal” vibration patterns. Model parameters were fine-tuned to optimize performance based on the characteristics of each technique’s dataset.

Step IV. Model Training and Testing

For each machine learning model employed, training and testing were conducted on the synthetic dataset to evaluate its performance in classifying vibration anomalies. The training process for each model followed these steps:

- *Train-Test Split:* The dataset for each technique was divided into 80% for training and 20% for testing.
- *Model Training:* Each model was trained on the labelled training dataset. For some models, such as K-NN and GBM, hyper parameters (e.g., the number of neighbors and learning rate) were adjusted based on initial training and validation results.
- *Prediction and Evaluation:* After training, each model was evaluated on the reserved test set. Predictions were made for all test samples, and the predicted labels were compared to the actual class labels to assess performance.

Step V. Performance Evaluation Metrics

To comprehensively evaluate the performance of each classifier, multiple metrics were used to provide a well-rounded assessment of each model’s effectiveness:

- *Accuracy:* Measures the percentage of correct predictions, indicating the overall effectiveness of the model in classifying normal and abnormal patterns.
- *Precision:* Evaluates the proportion of true positive predictions among all positive predictions, assessing the model’s ability to minimize false positives.
- *Recall:* Measures the proportion of true positive predictions among all actual positives, reflecting the model’s sensitivity in detecting anomalies.
- *F1-score:* Combines precision and recall into a single metric, particularly useful for imbalanced datasets.
- *ROC AUC:* Assesses the model’s effectiveness in distinguishing between classes by calculating the area under the receiver operating characteristic (ROC) curve, independent of a specific threshold value.

The performance of each model for the P300 speller across different techniques (ECPT, AS, BTT, LDV, and SG) was analyzed and recorded to determine the best classifier for each technique. The evaluation demonstrated that the Random Forest model yielded the highest estimated accuracy of 1.00 for the ECPT dataset. Additionally, K-NN shows remarkable precision scores of 0.49 and 0.52 for the AS and BTT datasets, respectively. The findings for each technique and model were presented in tables and visualized using bar charts to facilitate comparison and identify the most effective model for each vibration monitoring technique.

Step VI. Visualization and Comparative Analysis. To compare the performance metrics of each model, bar plots and comparison charts were created for the five vibration measurement methods. These visualizations provided an intuitive way to analyze the strengths and weaknesses of each model, highlighting specific classifiers that performed well or poorly in certain aspects.

Insights gained from these comparisons were applied to the evaluation of models and techniques in actual CCPP processes.

4. Results and Discussion

4.1. The Performance of Combining Machine Learning Models with Vibration Measurement Techniques

4.1.1. Combining Machine Learning Models with ECPT Technique

From Figure 3, the Random Forest classifier demonstrated exceptional performance on ECPT data, achieving accuracy score of 1.00 for all criteria. These results suggest that, among all models analyzed, Random Forest is the most effective for ECPT datasets, likely due to its ability to capture complex vibration pattern fluctuations.

K-NN performed reasonably well, achieving an accuracy of 0.47, but ensemble models, particularly RF and GBM, outperformed it significantly.

4.1.2. Combining Machine Learning Models with AS Technique

For AS data, Random Forest and GBM achieved accuracy scores of 0.49 and 0.52, respectively. K-NN also performed well, with an accuracy of 0.49, making it a viable option in scenarios where simpler models are preferred for efficiency in terms of time and computational resources. SVM, however, delivered the lowest performance, with an accuracy of 0.48, indicating its limitations in handling highly complex accelerometer data. Figure 4 displays comparison of the performance of different machine learning models on AS data as a bar chart.




Figure 3. Comparison of the performance of different machine learning models on ECPT data

Source: by Al-T.W.K. Fahmi




Figure 4. Comparison of the performance of different machine learning models on AS data

Source: by Al-T.W.K. Fahmi

4.1.3. Combining Machine Learning Models with BTT Technique

From Figure 5, the K-NN classifier performed surprisingly well on BTT data, achieving an accuracy of 0.52, which was comparable to Random Forest and superior to SVM, which scored 0.48.

These results suggest that the distance-based approach in K-NN is particularly effective when data points are closely clustered, as seen in BTT data. Random Forest and GBM also performed well, with accuracy scores of 0.52 and 0.49, respectively.




Figure 5. Comparison of the performance of different machine learning models on BTT data

Source: by Al-T.W.K. Fahmi

4.1.4. Combining Machine Learning Models with LDV Technique

LDV data posed challenges for all classifiers, as none achieved an accuracy higher than 0.52. GBM and Random Forest performed similarly, with accuracy scores of 0.48 and 0.44, respectively. K-NN struggled with the dispersed

nature of the LDV data, yielding the lowest accuracy (0.44). These findings suggest that more sophisticated models or improved preprocessing techniques may be required for effective LDV data classification. The bar chart below, Figure 6 illustrates comparison of the performance of different machine learning models on LDV data.




Figure 6. Comparison of the performance of different machine learning models on LDV data

Source: by Al-T.W.K. Fahmi

4.1.5. Combining Machine Learning Models with SG Technique

From Figure 7, Random Forest and K-NN produced comparable results, both achieving an accuracy of 0.49. GBM followed closely with an

accuracy of 0.44, while SVM scored 0.48. These findings indicate that simpler models like K-NN can be effective for techniques such as SG, where the data characteristics are relatively straightforward.




Figure 7. Comparison of the performance of different machine learning models on SG data

Source: by Al-T.W.K. Fahmi

4.2. Comparative Analysis Across All Techniques

A comparative analysis of all techniques revealed that Random Forest consistently outperformed other models, particularly with ECPT data, where it achieved a perfect classification score across all metrics. K-NN, despite its simplicity, performed well with AS and BTT data, demonstrating its suitability in situations where computational efficiency is crucial. GBM also exhibited

strong performance, especially for AS data, where it achieved the highest accuracy (0.52) among the ensemble methods. In contrast, SVM consistently underperformed across all techniques, indicating difficulties in handling complex vibration patterns commonly found in CCPPs. Figure 8 compares the performance of all machine learning models used in this research with a combination of different vibration measurement techniques.




Figure 8. Consolidated bar chart to compare accuracy across all models and techniques

Source: by Al-T.W.K. Fahmi

4.3. Key Observations and Insights

1. Model-Dependent Performance:

- Random Forest exhibited the strongest overall performance, particularly with ECPT data, due to its ensemble learning approach and ability to recognize complex data patterns.

- K-NN produced competitive results, especially for techniques involving closely clustered data points (e.g., AS and BTT), making it a viable option for scenarios with limited computational resources.

2. Technique-Dependent Model Suitability:

- The analysis confirmed that Random Forest is the most suitable model for ECPT data, while K-NN performed best for AS and BTT datasets.

- LDV data proved difficult for classification due to its dispersed nature, suggesting that further data preprocessing or more advanced classification models could enhance performance.

3. Computational Efficiency vs. Accuracy:

- While Random Forest achieved the highest accuracy, K-NN offers a balance between efficiency and accuracy, making it suitable for simpler data patterns such as AS and SG when computational resources are limited.

The current study highlights that Random Forest is the optimal classifier for detecting vibration anomalies in CCPPs, particularly when dealing with complex data from ECPT and AS. However, K-NN emerges as a resource-efficient alternative for simpler datasets, performing effectively on AS and BTT data. These findings emphasize the importance of selecting the appropriate machine learning model based on the nature of the vibration data and the computational constraints of the monitoring system.

Conclusion and Future Direction

This study evaluated the performance of four machine learning classifiers — Random Forest (RF), Gradient Boosting Machine (GBM), Support Vector Machine (SVM), and K-Nearest Neighbors (K-NN) — in classifying three groups of vibration data (N, M, and L) for combined cycle power plants (CCPPs). Various advanced sensors, including Eddy Current Proximity Transducers (ECPT),

Accelerometer Sensors (AS), Blade Tip Timing (BTT), Laser Doppler Vibrometers (LDV), and Strain Gauges (SG), were used to generate synthetic vibration data for fault diagnosis.

Among the classifiers, Random Forest demonstrated the highest efficiency, achieving perfect accuracy, precision, recall, F1-score, and ROC AUC (all equal to 1.00) when using ECPT data, highlighting its robustness with large and diverse features. While K-NN is less complex than SVM, it still produced satisfactory results, particularly with AS and BTT data, achieving accuracy scores of 0.49 and 0.52, respectively. This suggests that K-NN can be an effective choice when computational efficiency is a priority. In contrast, SVM exhibited comparatively lower performance, indicating its limitations in handling complex vibration data. Overall, the findings suggest that RF is the most suitable model for analyzing complex datasets, while K-NN provides a viable and efficient alternative for simpler data structures. Selecting the appropriate machine learning model and sensor technique is crucial for enhancing predictive maintenance in CCPPs.

To further improve vibration analysis and predictive maintenance in CCPPs, future research should explore the following directions:

- *Utilizing Real-World Data:* Validate the proposed models using actual vibration data from CCPP environments to ensure durability and accuracy in real-world conditions.

- *Developing Hybrid Models:* Combine the strengths of Random Forest and K-NN to develop a hybrid model that optimizes both accuracy and computational efficiency.

- *Applying Edge Computing:* Deploy lightweight models, such as K-NN, on edge computing devices for real-time vibration monitoring and anomaly detection directly within CCPP systems.

By addressing these areas, future studies can enhance the reliability, efficiency, and real-time applicability of machine learning models in CCPP vibration monitoring and predictive maintenance.

References

1. Brahimi L, Hadroug N, Iratni A, Hafaifa A, Colak I. Advancing predictive maintenance for gas turbines: An intelligent monitoring approach with ANFIS, LSTM,

and reliability analysis. *Computers & Industrial Engineering*. 2024;191:110094. <https://doi.org/10.1016/j.cie.2024.110094>

2. Fahmi ATWK, Reza Kashyzadeh K, Ghorbani S. Fault detection in the gas turbine of the Kirkuk power plant: An anomaly detection approach using DLSTM-Autoencoder. *Engineering Failure Analysis*. 2024;160:108213. <https://doi.org/10.1016/j.engfailanal.2024.108213>

3. Fu W, Hopkins WS. Applying machine learning to vibrational spectroscopy. *The Journal of Physical Chemistry A*. 2018;122(1):167–171. <https://doi.org/10.1021/acs.jpca.7b10303>

4. Fahmi ATWK, Reza Kashyzadeh K, Ghorbani S. A comprehensive review on mechanical failures cause vibration in the gas turbine of combined cycle power plants. *Engineering Failure Analysis*. 2022;134:106094. <https://doi.org/10.1016/j.engfailanal.2022.106094>

5. Salilew WM, Karim ZAA, Lemma TA. Investigation of fault detection and isolation accuracy of different Machine learning techniques with different data processing methods for gas turbine. *Alexandria Engineering Journal*. 2022;61(12):12635–12651. <https://doi.org/10.1016/j.aej.2022.06.026>

6. Yang X, Bai M, Liu J, Liu J, Yu D. Gas path fault diagnosis for gas turbine group based on deep transfer learning. *Measurement*. 2021;181:109631. <https://doi.org/10.1016/j.measurement.2021.109631>

7. Sudhakar GNDS, Sekhar AS. Coupling misalignment in rotating machines: modelling, effects and monitoring. *Noise & Vibration Worldwide*. 2009;40(1):17–39. <https://doi.org/10.1260/0957-4565.40.1.17>

8. Sinha JK, Hahn W, Elbbah K, Tasker G, Ullah I. Vibration investigation for low pressure turbine last stage blade failure in steam turbines of a power plant. *Proceedings of the ASME Turbo Expo 2012: Turbine Technical Conference and Exposition. Volume 7: Structures and Dynamics, Parts A and B*. 2012;44731:363–371. <https://doi.org/10.1115/GT2012-70129>

9. Fahmi AWK, Reza Kashyzadeh K, Ghorbani S. Smart maintenance strategies in combined cycle power plant. *Journal of Computational & Applied Research in Mechanical Engineering (JCARME)*. 2024;14(1):35–46. <https://doi.org/10.22061/jcarme.2024.10797.2415>

10. Voris J, Saxena N, Halevi T. Accelerometers and randomness: perfect together. *Proceedings of the fourth ACM conference on Wireless network security*. 2011;115–126. <http://doi.org/10.1145/1998412.1998433>

11. Mevissen F, Meo M. A review of NDT/structural health monitoring techniques for hot gas components in

gas turbines. *Sensors*. 2019;19(3):711. <https://doi.org/10.3390/s19030711>

12. Wang KS, Guo D, Heyns PS. The application of order tracking for vibration analysis of a varying speed rotor with a propagating transverse crack. *Engineering Failure Analysis*. 2012;21:91–101. <https://doi.org/10.1016/j.engfailanal.2011.11.020>

13. Anand LDV, Hepsiba D, Palaniappan S, Vijayakumar P, Sumathy B, Rani SS. Automatic strain sensing measurement on steel beam using strain gauge. *Materials Today: Proceedings*. 2021;45:2578–2580. <https://doi.org/10.1016/j.matpr.2020.11.274>

14. Machine Learning Random Forest Algorithm — Javatpoint. Available from: <https://www.scribd.com/document/681586333/Machine-Learning-Random-Forest-Algorithm-Javatpoint> (accessed: 12.02.2025).

15. Maleki E, Unal O, Sahebari SMS, Reza Kashyzadeh K. A novel approach for analyzing the effects of Almen intensity on the residual stress and hardness of shot-peened (TiB+ TiC)/Ti–6Al–4V composite: Deep learning. *Materials*. 2023;16(13):4693. <https://doi.org/10.3390/ma16134693>

16. Kapler J, Campbell S, Credland M. Continuous automated flux monitoring for turbine generator rotor condition assessment. *Iris Power Engineering Inc*. 2004;27. Available from: <https://www.marubun.co.jp/wp-content/uploads/a7ijkd000000119x/epri-2004.pdf> (accessed: 12.02.2025).

17. Zhang J, Duan F, Niu G, Jiang J, Li J. A blade tip timing method based on a microwave sensor. *Sensors*. 2017;17(5):1097. <https://doi.org/10.3390/s17051097>

18. Lai H, Adams II TA. Life cycle analyses of SOFC/gas turbine hybrid power plants accounting for long-term degradation effects. *Journal of Cleaner Production*. 2023;412:137411. <https://doi.org/10.1016/j.jclepro.2023.137411>

19. Vyroubal D. Eddy-current displacement transducer with extended linear range and automatic tuning. *IEEE Transactions on Instrumentation and Measurement*. 2009;58(9):3221–3231. <https://doi.org/10.1109/TIM.2009.2017165>

20. Zielinski M, Ziller G. Noncontact vibration measurements on compressor rotor blades. *Measurement Science and Technology*. 2000;11(7):847. <https://doi.org/10.1088/0957-0233/11/7/301>

21. Schewe M, Rembe C. Signal diversity for laser-Doppler vibrometers with raw-signal combination. *Sensors*. 2021;21(3):998. <https://doi.org/10.3390/s21030998>

22. Lee YJ, Ju YH. An assessment of insulation condition for generator rotor windings. *IEEE 2008 International Conference on Condition Monitoring and Diagnosis*. 2008;543–545. <https://doi.org/10.1109/CMD.2008.4580345>

About the authors

Al-Tekreeti Watban Khalid Fahmi, Ph.D. student of the Department of Mechanical Engineering, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0000-0002-2752-5750; e-mail: wat1680@gmail.com

Kazem Reza Kashyzadeh, Ph.D. in Technical Sciences, Professor of the Department of Transport Equipment and Technology, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0000-0003-0552-9950; e-mail: reza-kashi-zade-ka@rudn.ru

Siamak Ghorbani, Candidate of Technical Sciences, Associate Professor of the Department of Mechanical Engineering Technologies, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; eLIBRARY SPIN-code: 8272-2337, ORCID: 0000-0003-0251-3144; e-mail: gorbani-s@rudn.ru

Sergei A. Kupreev, Doctor of Sciences (Techn.), Professor of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; eLIBRARY SPIN-code: 2287-2902, ORCID: 0000-0002-8657-2282; e-mail: kupreev-sa@rudn.ru

Oleg E. Samusenko, Ph.D of Technical Sciences, Head of the Department of Innovation Management in Industries, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0000-0002-8350-9384, Scopus Author ID: 57201881755, eLIBRARY SPIN-code: 6613-5152; e-mail: samusenko@rudn.ru

Сведения об авторах

Фахми Ал-Текреети Ватбан Халид, аспирант кафедры техники и технологий транспорта, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0000-0002-2752-5750; e-mail: wat1680@gmail.com

Реза Каши Заде Казем, кандидат технических наук, профессор кафедры техники и технологий транспорта, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0000-0003-0552-9950; e-mail: reza-kashi-zade-ka@rudn.ru

Горбани Сиамак, кандидат технических наук, доцент базовой кафедры машиностроительных технологий, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-code: 8272-2337, ORCID: 0000-0003-0251-3144; e-mail: gorbani-s@rudn.ru

Купреев Сергей Алексеевич, доктор технических наук, профессор кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-код: 2287-2902, ORCID: 0000-0002-8657-2282; e-mail: kupreev-sa@rudn.ru

Самусенко Олег Евгеньевич, кандидат технических наук, заведующий кафедрой инновационного менеджмента в отраслях промышленности, инженерная академия, Российский университет дружбы народов, Российская Федерация; 117198, Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-код: 6613-5152, ORCID: 0000-0002-8350-9384; e-mail: samusenko@rudn.ru



DOI: 10.22363/2312-8143-2025-26-3-288-297

EDN: YSDKNI

Научная статья / Research article

Статистический анализ функционирования модифицированных генетических алгоритмов для автоматизированного составления расписания многоуровневого вуза

Д.С. Захаров^a, А.Ф. Рогачев^b

^a Себряковский филиал, Волгоградский государственный технический университет, Михайловка, Российская Федерация

^b Волгоградский государственный технический университет, Волгоград, Российская Федерация

✉ rafr@mail.ru

История статьи

Поступила в редакцию: 28 апреля 2025 г.

Доработана: 23 июня 2025 г.

Принята к публикации: 10 июля 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Построение расписания занятий учебного заведения, в частности многоуровневого вуза, сочетающих в своих организационно-педагогических структурах несколько уровней обучения, включая профессионалитет, среднее профессиональное и высшее образование, а также подготовку научно-педагогических кадров высшей квалификации, является трудоемкой задачей. Рассмотрен компьютеризованный подход к процессу построения модели и его оптимизации. Используются методы системного анализа и модификации генетических алгоритмов (ГА), обоснованы структура исходных данных для задачи составления и оптимизации учебных расписаний с применением метода штрафных функций для учета ресурсных и иных ограничений. Предложен статистический подход и реализован модуль сбора и визуализации статистики с возможностью оперативной корректировки гиперпараметров и математической модели ГА. Приведены примеры решения задачи построения расписаний многоуровневого вуза с применением ГА. Разработанная компьютерная программа обеспечивает построение расписания учебных занятий многоуровневого вуза, эффективного по обоснованному интегральному критерию качества и с учетом ограничений.

Ключевые слова: учебное расписание, системный анализ, ресурсы, ограничения, критерий качества, генетический алгоритм

Вклад авторов

Захаров Д.С. — сбор, создание и обработка базы данных, разработка программы для ЭВМ; анализ данных, написание текста, подготовка рисунков; Рогачев А.Ф. — концепция и дизайн исследования, анализ данных, написание текста, подготовка рисунков.

Благодарности

Авторы благодарят директора Себряковского филиала Волгоградского государственного технического университета кандидата экономических наук доцента Карпушову Светлану Евгеньевну за содействие в сборе эмпирических материалов, использованных при подготовке статьи.

© Захаров Д.С., Рогачев А.Ф., 2025



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License
<https://creativecommons.org/licenses/by-nc/4.0/legalcode>

Для цитирования

Захаров Д.С., Рогачев А.Ф. Статистический анализ функционирования модифицированных генетических алгоритмов для автоматизированного составления расписания многоуровневого вуза // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 288–297. <http://doi.org/10.22363/2312-8143-2025-26-3-288-297>

Statistical Analysis of the Performance of Modified Genetic Algorithms for Automated Compilation of a Multilevel University Scheduling

Dmitry S. Zakharov^a, Aleksey F. Rogachev^b

^aSebryakovsky branch, Volgograd State Technical University, *Mikhailovka, Russian Federation*

^bVolgograd State Technical University, *Volgograd, Russian Federation*

✉ rafr@mail.ru

Article history

Received: April 28, 2025

Revised: June 23, 2025

Accepted: July 10, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. The construction of a class schedule of an educational institution and, especially, a multilevel higher education institution, combining in its organizational and pedagogical structures several levels of education, including professional, secondary vocational and higher education, as well as training of scientific and pedagogical staff of higher qualification, is a time-consuming task. The study considers a computerized approach to the process of building a model of its optimization. The study uses the methods of system analysis and modification of genetic algorithms (GA), substantiates the structure of initial data for the task of compiling and optimizing training schedules using the method of penalty functions to account for resource and other constraints. A statistical approach is proposed, and a statistics collection and visualization module is implemented, which allows for the operative correction of hyperparameters and the mathematical model of the GA. The examples are provided to illustrate the problem of creating schedules for a multilevel university using GA. The developed computer program provides the creating of the schedule of academic classes of a multilevel university, effective according to the integral quality criterion substantiated taking into account the limitations.

Keywords: training schedule, system analysis, resources, constraints, quality criterion, genetic algorithm

Authors' contribution

Zakharov D.S. — collection, creation and processing of database, development of computer program; data analysis, text composition, figure preparation; *Rogachev A.F.* — concept and design of the study, data analysis, text composition, figure preparation.

Acknowledgements

The authors would like to thank Svetlana E. Karpushova, PhD in Economics, Associate Professor, Director of the Sebryakovsky Branch of the Volgograd State Technical University, for her assistance in collecting empirical materials used in the preparation of the article.

For citation

Zakharov DS, Rogachev AF. Statistical analysis of the performance of modified genetic algorithms for automated compilation of a multilevel university scheduling. *RUDN Journal of Engineering Research*. 2025;26(3):288–297. (In Russ.) <http://doi.org/10.22363/2312-8143-2025-26-3-288-297>

Введение

Построение расписания занятий учебного заведения, в том числе вуза, является трудоемкой задачей, относящейся к классу NP-сложных [1]. Громоздкость решения таких задач характерна для многоуровневых вузов, сочетающих в своих организационно-педагогических структурах несколько уровней обучения, включая профессионалитет, среднее профессиональное и высшее образование, а также подготовку научно-педагогических кадров высшей квалификации. При этом необходимо учитывать многочисленные и отчасти противоречивые требования ограниченности наличных ресурсов и нечеткость интегрального многокомпонентного критериев оценки качества полученного расписания учебных занятий для вуза в целом и отдельных участников образовательного процесса.

Проблема увязки предъявляемых требований в формируемом учебном расписании дополнительно усугубляется необходимостью учета нелинейности образовательного процесса, для которой характерна «возрастающая открытость и взаимопересечение образовательных и культурных сред»¹. Как школы, так и высшие учебные заведения перестают быть „вещью в себе“, оказываются поставленными в обстоятельства, когда одновременно должны предоставлять субъектам возможности для обучения в интеграции разнообразных сред и поддерживать собственную образовательную специфику», отмечаемая в работе [2].

Как отмечают С.В. Аранова, Л.К. Боровик, Н.В. Примчук, упомянутая нелинейность определяет такие характеристики, как: «динамичный характер в открытом взаимодействии с внешней средой; возможность внесения изменений на уровне целей, содержания и результатов образования с учетом социальных и культурных вызовов; самореализация обучающихся

за счет выстраивания индивидуальных образовательных маршрутов» [2]. Цитируемые авторы отмечают ряд ключевых моментов, необходимых при составлении расписания «Математическое моделирование и автоматизация процесса реализации учебного расписания; Типологизация и формирование требований к учебному расписанию с учетом стандартов и регламентов; методы и алгоритмы построения расписания» [3].

Известны различные математико-алгоритмические подходы к решению задачи оптимизации учебного расписания, исследованные в работах А.С. Хасухаджиева, М.Э. Нагорных, И.И. Холода, В.С. Иванова, В.А. Бабкина, И.С. Григорьева и других исследователей, включая математическое моделирование и специализированные фреймворки [4; 5], мультиагентные системы [3; 6; 7] и другие методы.

В качестве эффективного подхода при составлении расписания вуза, как большой многокомпонентной системы, ряд авторов рекомендует метод компьютерного решения задачи оптимизации при составлении расписаний многоуровневого вуза на основе генетического алгоритма (ГА), являющегося эвристическим подвигом искусственного интеллекта (ИИ) [8].

С целью системного семантического описания предметной области задачи составления учебных расписаний обоснован онтологический подход к формированию структуры ее данных² [1]. Разработанные компьютерные программы обеспечивают построение расписания учебных занятий многоуровневого вуза. Известны различные методы оценки и реализации эффективного интегрального критерия качества, в том числе на основе комбинированных штрафных функций для учета ограничений математической модели оптимального расписания.

С учетом NP-сложности рассматриваемой задачи, существенного времени счета даже на современных быстродействующих ЭВМ, достигающих десятков минут, и необходимости опе-

¹ Смоленцева Т.Е. Технологии цифровой трансформации : практикум : учебное пособие. Москва : РТУ МИРЭА, 2023. 66 с. URL: <https://e.lanbook.com/book/368729> (дата обращения: 28.09.2024)

² Андрианова А.А., Исмаилов Л.Н., Мухтарова Т.М. Алгоритмизация и программирование. Практикум : учебное пособие. Санкт-Петербург : Лань, 2022. 240 с. URL: <https://e.lanbook.com/book/206258> (дата обращения: 12.03.2024)

ративных корректировок расписания, вопросы оптимизации машинного времени являются весьма актуальными, что невозможно без соответствующих статистических методов учета при модификации генетических алгоритмов и структуры входных и расчетных данных.

1. Методы

База данных (БД) решаемой задачи была сформирована на основе семантического описания предметной области проектирования расписания с учетом особенностей многоуровневого вуза, включающего частично пересекающиеся подмножества ресурсных ограничений для реализуемых уровней образования [9]. Для компьютерной поддержки решения оптимизационной задачи использованы методы онтологического инжиниринга, эволюционно-генетического и математического моделирования, статистического анализа, построения, а также нормализации и структурной оптимизации базы данных.

Эволюционная оптимизация учебного расписания была реализована посредством модифицируемого ГА, обобщенная схема которого представлена на рис. 1.

Исходный вариант расписания, представляющий собой начальную популяцию ГА, формировался случайно с использованием случайных значений хромосом.

Основные генетические операторы селекции, скрещивания и мутации [10–12] реализованы с возможностью модификации, в том числе в процессе реализации бесконечного цикла «while true» с предварительной проверкой условия останова.

Расчеты выполнялись на ПК со следующими характеристиками: CPU: 11th Gen Intel® Core™ i5-11400 2.60Ghz (12 CPUs); RAM: 32Gb; SSD: M.2 NVME 1Tb.

2. Результаты и обсуждение

Программа для формирования оптимизированного расписания включает специализированную базу данных и оптимизатор, реализованный на основе генетического алгоритма.




Рис. 1. Обобщенная блок-схема ГА с модифицируемыми генетическими операторами:
1 — останов, обозначены блоки генерации поколения;
2 — вычисление функции пригодности; 3 — проверка условия останова; 4 — задание основного цикла; 5 — блок реализации генетических операторов, 6 — блок модификации;
7 — обновление популяции; 8 — завершение ГА
Источники: выполнено Д.С. Захаровым, А.Ф. Рогачевым

Figure 1. Generalized flowchart of GA with modifiable genetic operators:
1 — breakpoint, the generation blocks are designated;
2 — calculation of the fitting function; 3 — checking of the breakpoint condition; 4 — definition of the main cycle;
5 — block for implementing genetic operators; 6 — modification block; 7 — population update; 8 — completion of genetic algorithms
Source: by D.S. Zakharov, A.F. Rogachev

2.1. Особенности разработанного программного средства для оптимизации расписания

Основные элементы БД, используемой для оптимизации расписания многоуровневого вуза и разработанной на основе онтологической модели, представлены в табл. 1.

Перед началом работы методист учебного отдела загружает файл учебной нагрузки и преподавателей [13]. В этом файле содержатся:

- а. название дисциплины;
- б. часы на дисциплину с разбивкой лекции/практики/лабы/СРС;
- с. прикрепленный преподаватель;
- д. кафедра, за которой закреплена дисциплина;
- е. прочие данные (коды дисциплин, кол-во групп бюджет/внебюджет, кол-во человек в группе, формы контроля и прочее).

После этого программа запускается на выполнение оптимизации расписания до момента останова по заданному критерию. Разработанная авторами зависимость, описывающая значение безразмерной функции пригодности единичного индивида в популяции и учитывающая окна в сетке расписания, равномерность загрузки, типы кабинетов, ограничения, а также предпочтения преподавателей, имеет вид

$$F = K_1 * \sum \left(N_1 * X + \frac{(N_2 + 1) * X}{2} + N_3 * Y + \frac{(N_4 + 1) * Y}{2} \right) + K_2 * \sum (G_D^2) + K_3 * \sum (Z_c) + K_4 * \sum (R_t) + K_5 * \sum (W_t), \quad (1)$$

где $K_1 \dots i$ — весовые (уравнивающие) коэффициенты показателей; $N_1 \dots j$ — количество окон различных типов; X — штраф за окна в сетке расписаний студентов; Y — штраф за окна в сетке расписаний преподавателей; G_D — показатель отклонения от среднего показателя занятий в день (для расчета равномерности нагрузки); D — день недели (1...6); Z_c — показатель штрафа за несоблюдение типа занятия и кабинета; C — ячейка расписания; R — штраф за несоблюдение ограничения; W — штраф за несоблюдение предпочтения; t — преподаватель/время/иной объект предпочтения или ограничения.

Таблица 1 / Table 1

Фрагмент БД с основными расчетными параметрами /
Snapshot of the database with the main calculated parameters

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	
1	form	block	co	co	co	co	name	direction	levels	semestr	contol_type	groups	count_all	count	count	type	cou	cou	cou	kafedra	zvan	step	dolz	uslov	teacher	hours	
2	ДН	Б1	0	1			Английский язык	09.03.02	ПБ		1 3	ИСТ11д-21, М11д-21	28	24	4	прак	1	1	ГД	доц	кн	дц	шт		Белозерова Е.В.		
3	ДН	Б1	0	10			Математика	09.03.02	ПБ		1 3	ИСТ11д-21, М11д-21	29	25	4	лек	1	1	МиеНД			ст	шсв		Киселева М.Н.		
4	ДН	Б1	0	11			Информатика	09.03.02	ПБ		1 3	ИСТ11д-21	25	25		лек	1	1	МиеНД			кн	доц	сов		Желудков М.А.	
5	ДН	Б1	0	24			История информации	09.03.02	ПБ		1 3	ИСТ11д-21	25	25		лек	1	1	МиеНД			преп	пч			Игнатов А.В.	
6	ДН	Б1	0	4			Социология и психологи	09.03.02	ПБ		1 3	ИСТ11д-21	25	25		лек	1	1	ГД	прф	дн	зк	шт		Сухинин А.В.		
7	ДН	Б1	0	27			Химия	09.03.02	ПБ		1 3	ИСТ11д-21	25	25		лек	1	1	МиеНД			ст	сов			Сидорова Н.Ю.	
8	ДН	Б1	0	29			Дискретная математика	09.03.02	ПБ		1 3	ИСТ11д-21	25	25		лек	1	1	МиеНД			кн	дц	шсв		Крутилин А.А.	
9	ДН	Б1	0	8			Культурология	09.03.02	ПБ		1 3	ИСТ11д-21	25	25		лек	1	1	ГД			кн	дц	шт		Балибардина Н.Г.	
10	ДН	Б1	8	8			Элективные дисциплины	09.03.02	ПБ		1 3	ИСТ11д-21, ИСТ21д-20	25	25		лек	1	1	ГД			кн	дц	шт		Дорофеева Г.А.	
11	ДН	Б1	0	2			История России, всеобщ	09.03.02	ПБ		2 3	ИСТ11д-21	25	25		лек	1	1	ГД			кн	дц	шт		Балибардина Н.Г.	
12	ДН	Б1	0	1			Английский язык	09.03.02	ПБ		2 3	ИСТ11д-21, М11д-21	28	24	4	прак	1	1	ГД	доц	кн	дц	шт		Белозерова Е.В.		
13	ДН	Б1	0	10			Математика	09.03.02	ПБ		2 3	ИСТ11д-21, М11д-21	29	25	4	лек	1	1	МиеНД			ст	шсв			Киселева М.Н.	
14	ЛН	Б1	0	6			Безопасность жизнедеят	09.03.02	ПБ		2 3	ИСТ11д-21	25	25		лек	1	1	ТЛМТЗ	доц	кн	ли	шт			Решетникова М.В.	

Источник: выполнено Д.С. Захаровым, А.Ф. Рогачевым / Source: by D.S. Zakharov, A.F. Rogachev

Таблица 2

Варианты модификации генетических операторов

Этапы реализации ГА	Варианты модификации	Результаты модификации
1. Построение начальной популяции	Построение начальной популяции по строгому алгоритму, с соблюдением жестких (обязательных) ограничений	Невозможность нарушения жестких ограничений в ходе работы алгоритма, отсутствие пересечений
2. Селекция	Механизм «встряски» при стагнации популяции, добавление новых неоптимизированных индивидов, сокращение популяции по принципу «катаклизма»	Сокращение вероятности ухода алгоритма в локальные минимумы и периоды однообразия популяций
3. Скрещивание	Групповое скрещивание особей популяции с возможностью скрещиваться более двух особей	Увеличение разнообразия индивидов
4. Мутация	Двухэтапная мутация: вынужденная, в случае нахождения пересечений отдельных генов, и случайная мутация	Уменьшение вероятности появления нежестких ограничений, разнообразие индивидов
5. Гиперпараметры ГА	Гибкая подстройка и адаптация параметров ГА (размер популяции, количество скрещиваемых индивидов, вероятность мутации и т.д.)	Ускорение работы алгоритма и более эффективное использование ресурсов ЭВМ

Источник: выполнено Д.С. Захаровым, А.Ф. Рогачевым

Table 2

Modification options for genetic operators

Stages of GA implementation	Modification options	Modification results
1. Building the initial population	Building an initial population according to a strict algorithm, subject to strict (mandatory) restrictions	The impossibility of violating strict restrictions during the operation of the algorithm, the absence of intersections
2. Breeding	The mechanism of “shaking up” during population stagnation, the addition of new unoptimized individuals, the reduction of the population according to the principle of “cataclysm”	Reducing the probability of the algorithm going into local minima and periods of population uniformity
3. Crossbreeding	Group interbreeding of individuals of the population with the possibility of interbreeding more than two individuals	Increasing the diversity of individuals
4. Mutation	Two-stage mutation: forced, in case of intersections of individual genes, and accidental mutation	Increasing the diversity of individuals. Reducing the likelihood of non-rigid restrictions, diversity of individuals
5. Hyperparameters of GA	Flexible adjustment and adaptation of GA parameters (population size, number of individuals crossed, probability of mutation, etc.)	Acceleration of the algorithm and more efficient use of computer resources

Source: by D.S. Zakharov, A.F. Rogachev

Представленные в табл. 2 возможные варианты модификации генетических операторов и элементов ГА способствуют уменьшению ресурсоемкости проводимых операций, позволяют строго соблюдать жесткие ограничения при составлении расписаний, а также снижают влияние системных недостатков ГА на конечный результат.

2.2. Результаты численных экспериментов

Результаты численных экспериментов расчета оптимального расписания с использованием разработанной программы методом ГА, использующей модуль «Статистика» [14], представлены на рис. 2. Упомянутый модуль статистического анализа обеспечивает сбор, анализ и отображения статистики работы ГА, позволяет в автоматизированном режиме корректировать гиперпараметры ГА, его характеристики, а также параметры ограничений при оптимизации расписаний.

Проведенные расчеты на ПК показали, что отбор индивидов популяции в количестве 50 %, после подсчета функции приспособленности показала лучшую эффективность по времени и конфигурации нисходящего характера графиков, при чем 80 %. Потомство дают 50 % лучших особей (из 1000 особей), при этом время

расчета составило 8 минут и останов происходил в районе 90 поколений (эпох).

На рис. 3 представлены результаты численного эксперимента, предусматривающего применение более широкого разнообразия особей для дальнейшего скрещивания. Отметим, что 80 % лучших особей дают потомство (1000 особей), при этом останов происходил ориентировочно на 280-м поколении, а время расчета составляло порядка 30 минут.

Анализ графика на рис. 3 показывает, что увеличение количества особей, участвующих в турнирном отборе дальнейших популяций, дает отрицательную динамику поиска оптимального результата.

Анализ конфигурации диаграммы на рис. 3 показывает, что высокий показатель доли скрещиваемых в поколении особей дает негативный эффект кратковременного ухудшения показателя пригодности популяции (синие пики на графике), а также способствует увеличению времени работы алгоритма и конкретной ресурсозатратности. Более низкое значение показателя (30–40 %) дает эффект недостаточности генного разнообразия индивидов и приводит процесс расчета оптимального решения к стагнации популяции и невозможности применения останова по достижении оптимального результата функции приспособленности (рис. 4).




Рис. 2. Результаты численных экспериментов с использованием модуля «Статистика» разработанной программы
 Источник: выполнено Д.С. Захаровым, А.Ф. Рогачевым

Figure 2. Results of numerical experiments using the developed program module "Statistics"
 Source: by D.S. Zakharov, A.F. Rogachev




Рис. 3. Результаты численного эксперимента при увеличенной доле скрещиваемых хромосом особей
 Источник: выполнено Д.С. Захаровым, А.Ф. Рогачевым

Figure 3. Results of numerical experiment at increased proportion of crossed chromosome individuals
 Source: by D.S. Zakharov, A.F. Rogachev




Рис. 4. Результаты численного эксперимента при уменьшенной доле скрещиваемых особей до 30 %

И с т о ч н и к: выполнено Д.С. Захаровым, А.Ф. Рогачевым

Figure 4. Results of numerical experiment at reduced proportion of crossbred individuals up to 30%

S o u r c e: by D.S. Zakharov, A.F. Rogachev

Анализ диаграммы на рис. 4 показывает, что низкий уровень доли скрещиваемых особей приводит к заикливанию алгоритма, чего необходимо избегать. Диаграмма показывает, что на определенном этапе большая часть особей пришла к единому неоптимальному решению и не может из него выбраться. Случайная мутация способствует выходу на оптимальное решение, но зачастую не позволяет этого добиться из-за ухудшения показателя целевой функции пригодности, и, соответственно, непрохождения в следующую популяцию.

Совершенствование функционирования эволюционных вычислений при решении задачи оптимизации расписания многоуровневого вуза можно совмещать с различными модификациями реализациями непосредственно ГА.

Обеспечиваемый при этом синергетический эффект также может способствовать повышению эффективности оптимизации и, прежде всего, сокращению времени достижения приемлемого времени счета по задаваемому кри-

терию его качества. Для этого можно использовать отдельную программу grid-оптимизации, которую удобно разработать на языке Python.

Заключение

Проведенные теоретические и численные исследования создания компьютерной программы для оптимизации составления расписания многоуровневого вуза позволили сформулировать следующие выводы.

1. Разработанный программный комплекс, включающий блоки ввода исходных данных (учебных планов дисциплин, аудиторного фонда, учебных групп, преподавателей дисциплин и др.), формирования начального варианта расписания методом случайного выбора, оптимизации расписания методом ГА, модуля статистики, а также вывода результатов оптимизации обеспечивает автоматизированное построение оптимального расписания по заданному критерию, при этом время счета для заданного

многоуровневого филиала ВолгГТУ составляло порядка 6...30 минут.

2. Разработанный модуль статистики обеспечивает возможность проведения автоматизированного тестирования различных параметров с проведением анализа и вывода на экран статистических данных о процессе тестирования. Также данный модуль на основе проведенных тестов способен выдавать оптимальный набор параметров на основе конкретных данных, что можно использовать для оценки эффективности функционирования текущей конфигурации ГА, сравнения вариантов его модификации и совершенствования гиперпараметров, что следует выполнять для каждого набора параметров оптимизируемого расписания, а также при их существенном изменении.

3. Совершенствование функционирования эволюционно-генетического алгоритма при решении задачи оптимизации расписания многоуровневого вуза возможно совмещать с различными модификациями реализации непосредственно ГА. Достижимый при этом синергетический эффект может способствовать повышению эффективности оптимизации и сокращению времени ее достижения по задаваемому критерию его качества.

Список литературы

1. Rogachev A.F., Zakharov D.S. A Systematic approach to ontology construction for automating the scheduling of a multilevel university // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 1. С. 39–51. <http://doi.org/10.22363/2312-8143-2025-26-1-39-51>
2. Аранова С.В., Боровик Л.К., Примчук Н.В. Модель построения учебного расписания в нелинейном образовательном процессе педагогического вуза // Известия Волгоградского государственного педагогического университета. 2025. № 2 (195). С. 61–72. EDN: TATJTE
3. Хасухаджиев А.С.А. Модели и алгоритмы формирования учебного расписания с учетом заданного набора требований : автореф. дис. ... д-ра пед. наук. Астрахань, 2022. 185 с. EDN: NVFEGD
4. Фураева И.И., Сеньковская А.А. Моделирование процесса распределения учебной нагрузки кафедры с использованием жадного алгоритма // Математические структуры и моделирование. 2017. № 4 (44). С. 101–109. <http://doi.org/10.24147/2222-8772.2017.4.101-109> EDN: ZWAXXL
5. Babkin V.A., Chepurnov S.V., Boldyrev R.O., Ignatov A.V., Knyazev A.P., Zakharov D.S., Borisov D.A., Yanborisov V.M., Titova E.S., Belousova V.S., Artsis M.I., Zaiakov G.E. Quantum-chemical calculation of the graphene oxide molecule in the framework of the Hoffman model by the MNDO method // Oxidation Communications. 2021. Vol. 44. No. 1. С. 22–26. EDN WARFBK
6. Нагорных М.Э. Мультиагентная система формирования расписания в вузе // Вестник Российского нового университета. Серия: Сложные системы: модели, анализ и управление. 2022. № 2. 99–108. <http://doi.org/10.18137/RNU.V9187.22.02.P.099> EDN: LNIWWU
7. Холод И.И., Иванов В.С., Григорьев И.С., Корытов П.В., Ковынев М.В. Опыт автоматизации процесса составления расписания в вузе // Cloud of Science. 2020. Т. 7. № 4. С. 844–868. EDN: NVZDQW
8. Rogachev D.A., Rogachev A.F. Justification of Parameters Modifiable for Genetic Algorithms of Artificial Intelligence for Solving Multi-Criteria Optimization Problems // Inventive Communication and Computational Technologies: Proceedings of ICICCT 2024, Coimbatore. Singapore : Springer Nature Singapore Pte Ltd, 2024. Vol. 23. P. 899–910. EDN: YUELQB
9. Карпушова С.Е., Пацюк Е.В., Рыжова О.А., Инькова Н.А., Захаров Д.С. База данных автогенератора учебных расписаний / Свидетельство о регистрации базы данных RU 2023624808, 20.12.2023. Заявка от 13.12.2023. EDN: KSTGPT
10. Москвитин А.А. Данные, информация, знания: методология, теория, технологии. 2-е изд., стер. Санкт-Петербург : Лань, 2023. 236 с. URL: <https://e.lanbook.com/book/288968> (дата обращения: 13.02.2025).
11. Захаров Д.С. Применение модифицированных генетических алгоритмов для решения эволюционных задач теории расписаний // Вестник Дагестанского государственного технического университета. Технические науки. 2023. Т. 50. № 2. 90–97. <http://doi.org/10.21822/2073-6185-2023-50-2-90-97> EDN: EUXQJO
12. Захаров Д.С. Автогенератор учебных расписаний / Свидетельство о регистрации программы для ЭВМ RU 2023687279, 13.12.2023. Заявка от 13.12.2023. EDN: EWXCUJ
13. Patsyuk E.V., Zakharov D.S., Inkova N.A., Krutulin A.A., Khachatryan S.Z. Intellectual Machines as Hi-Tech Ecological Innovations Created with the Help of Evolutionary Computation and Genetic Algorithms // Modern Global Economic System: Evolutional Development vs. Revolutionary Leap : Institute of Scientific Communications Conference. Cham : Springer Nature, 2021. Vol. 198. P. 1190–1197. http://doi.org/10.1007/978-3-030-69415-9_129 EDN: MCRRUL
14. Захаров Д.С., Захаров М.С. Модуль сбора статистики автогенератора учебных расписаний / Свидетельство о регистрации программы для ЭВМ RU 2024686891, 13.11.2024. Заявка от 13.11.2024. EDN: CAELXH

References

1. Rogachev AF, Zakharov DS. A systematic approach to building an ontology for automating the scheduling of a multi-level university. *RUDN Journal of Engineering Research*. 2025;26(1):39–51. <http://doi.org/10.22363/2312-8143-2025-26-1-39-51>
2. Aranova SV, Borovik LK, Primchuk NV. The model of making the school schedule in the non-linear educational process of pedagogical university. *Izvestia of the Volgograd State Pedagogical University*. 2025;2(195): 61–72. (In Russ.) EDN: TATJTE
3. Khasukhadzhiev ASA. *Models and algorithms for the formation of an educational schedule, taking into account a given set of requirements*: abstract of the dissertation of the Doctor of Pedagogical Sciences. Astrakhan, 2022. (In Russ.) EDN: NVFEGD
4. Furaeva II, Senkovskaya AA. Modeling the process of distributing the academic load of the department using a greedy algorithm. *Mathematical structures and modeling*. 2017;4(44):101–109. (In Russ.) <http://doi.org/10.24147/2222-8772.2017.4.101-109> EDN: ZWAXXL
5. Babkin VA, Chepurnov SV, Boldyrev RO, Ignatov AV, Knyazev AP, Zakharov DS, Borisov DA, Yanborisov VM, Titova ES, Belousova VS, Artsis MI, Zaikov GE. Quantum-chemical calculation of the graphene oxide molecule in the framework of the Hoffman model by the MNDO method. *Oxidation Communications*. 2021;44(1): 22–26. (In Russ.) <http://doi.org/10.35211/1990-5297-2021-5-252-22-26> EDN: WARFBK
6. Nagornyykh ME. Multi-agent scheduling system at the university. *Bulletin of the Russian New University. Series: Complex systems: models, analysis and management*. 2022;(2):99–108. (In Russ.) <http://doi.org/10.18137/RNU.V9I87.22.02.P.099> EDN: LNIWWU
7. Kholod II, Ivanov VS, Grigoriev IS, Korytov P, Kovynnev M. Experience in automating the scheduling process at a university. *Cloud of Science*. 2020;7(4):844–868. (In Russ.) EDN: NVZDQW
8. Rogachev DA, Rogachev AF. Justification of parameters modifiable for genetic algorithms of artificial intelligence for solving multi-criteria optimization problems. *Inventive Communication and Computational Technologies: Proceedings of ICICCT 2024*. Coimbatore, Singapore: Springer Nature Singapore Pte Ltd; 2024;23:899–910. EDN: YUELQB
9. Karpushova SE, Patsyuk EV, Ryzhova OA, Inkova NA, Zakharov DS. *Data base of the curriculum auto-generator*. Database registration certificate RU 2023624808, 12.20.2023. (In Russ.) EDN: KSTGPT
10. Moskvitin AA. *Data, information, knowledge: methodology, theory, technologies*. 2nd ed., erased. Saint Petersburg: Lan Publ.; 2023. (In Russ.) Available from: <https://e.lanbook.com/book/288968> (accessed: 13.02.2025)
11. Zakharov DS. Application of modified genetic algorithms for solving evolutionary problems of the theory of schedules. *Bulletin of Dagestan State Technical University. Technical sciences*. 2023;50(2):90–97. (In Russ.) <http://doi.org/10.21822/2073-6185-2023-50-2-90-97> EDN: EUXQJO
12. Zakharov DS. *Autogenerator of training schedules*. Certificate of registration of the program for computer RU 2023687279, 13.12.2023. (In Russ.) EDN: EWXCUJ
13. Patsyuk EV, Zakharov DS, Krutinin AA, Khachatryan SZ, Inkova NA. Intellectual Machines as Hi-Tech Ecological Innovations Created with the Help of Evolutionary Computation and Genetic Algorithms. *Modern Global Economic System: Evolutional Development vs. Revolutionary Leap : Institute of Scientific Communications Conference*. Cham : Springer Nature, 2021;198:1190–1197. http://doi.org/10.1007/978-3-030-69415-9_129 EDN: MCRRUL
14. Zakharov DS, Zakharov MS. *Module for collecting statistics of the curriculum auto-generator*. Computer program registration certificate RU 2024686891, 11.13.2024. (In Russ.) EDN: CAELXH

Сведения об авторах

Захаров Дмитрий Сергеевич, соискатель, старший преподаватель кафедры математических и естественнонаучных дисциплин Себряковского филиала, Волгоградский государственный технический университет, Российская Федерация, 400005, г. Волгоград, пр-т Ленина, д. 28; eLIBRARY SPIN-код: 8794-7672, ORCID: 0009-0009-6665-510X; e-mail: zakator@bk.ru

Рогачев Алексей Фруминович, доктор технических наук, профессор кафедры информационных систем в экономике, Волгоградский государственный технический университет, Российская Федерация, 400005, г. Волгоград, пр-т Ленина, д. 28; eLIBRARY SPIN-код: 8413-5020, ORCID: 0000-0002-3077-6622; e-mail: rafr@mail.ru

About the authors

Dmitry S. Zakharov, Applicant, Senior Lecturer of the Department of Mathematical and Natural Sciences, Sebyakovsky branch, Volgograd State Technical University, 28 Lenina ave., Volgograd, 400005, Russian Federation; eLIBRARY SPIN-code: 8794-7672, ORCID: 0009-0009-6665-510X; e-mail: zakator@bk.ru

Aleksey F. Rogachev, Doctor of Technical Sciences, Professor of the Department of Information Systems in Economics, Volgograd State Technical University, 28 Lenina ave., Volgograd, 400005, Russian Federation; eLIBRARY SPIN-code: 8413-5020, ORCID: 0000-0002-3077-6622; e-mail: rafr@mail.ru



DOI: 10.22363/2312-8143-2025-26-3-298-309
EDN: ZZNVXS

Научная статья / Research article

Сравнение моделей и методов классификации текста

А.В. Захарова[✉], А.Ю. Вишнякова^{id}, А.А. Детков^{id}

Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Екатеринбург, Российская Федерация
✉ zakharova.linusha@mail.ru

История статьи

Поступила в редакцию: 17 апреля 2025 г.

Доработана: 13 июня 2025 г.

Принята к публикации: 7 июля 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Рассмотрен процесс автоматической классификации текста и его составляющие. Актуальность данной темы обусловлена стремительным ростом объема данных и развитием технологий машинного обучения. Цель исследования — определение наилучших методов и моделей автоматической классификации текста. В качестве материалов для анализа были выбраны научные статьи, написанные в течение последних четырех лет, наиболее подходящие по теме. В результате определено, что эффективная предобработка текстовых данных должна состоять из нормализации, токенизации, удаления стоп-слов и стемминга или же лемматизации. Для представления текста целесообразно использовать модель BERT. Однако следует отталкиваться от условий конкретной задачи, в которых альтернативные подходы могут быть предпочтительнее. Наилучшими методами непосредственно классификации текста можно считать метод логистической регрессии, сверточные нейронные сети и RoBERTa. Выбор среди этих моделей зависит от назначения и технических возможностей.

Ключевые слова: обработка естественного языка, NLP, предобработка текста, представление текста, машинное обучение, нейронные сети

Вклад авторов

Вишнякова А.Ю., Детков А.А. — концепция и дизайн исследования; Захарова А.В. — обработка материалов, написание текста. Все авторы ознакомлены с окончательной версией статьи и одобрили ее.

Для цитирования

Захарова А.В., Вишнякова А.Ю., Детков А.А. Сравнение моделей и методов классификации текста // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 298–309. <http://doi.org/10.22363/2312-8143-2025-26-3-298-309>



Comparison of Text Classification Models and Methods

Angelina V. Zakharova[✉], Alina Yu. Vishnyakova^{ORCID}, Alexander A. Detkov^{ORCID}

Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russian Federation

✉ zakharova.linusha@mail.ru

Article history

Received: April 17, 2025

Revised: April 17, 2025

Accepted: July 7, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. The study considers the process of automatic text classification and its components. The relevance of this topic is due to the rapid growth of data and the development of machine learning technologies. The purpose of the study is to determine the best methods and models for automatic text classification. The scientific articles written over the past four years that are most suitable for the topic were selected as material for analysis. Consequently, it was determined that effective preprocessing of text data should consist of normalization, tokenization, removal of stop words and stemming or lemmatization. The BERT model is recommended to be used to represent the text. However, it is worth starting from the conditions of a specific task, in which alternative approaches may be preferable. The most effective methods of direct text classification are the logistic regression method, convolutional neural networks, and RoBERTa. The selection of a particular model is determined by the intended application and the technological capabilities available.

Keywords: natural language processing, NLP, text preprocessing, text representation, machine learning, neural networks

Authors' contribution

Vishnyakova A. Yu., Detkov A. A. — the concept and design of the study; Zakharova A. V. — processing materials, writing. All authors read and approved the final version of the article.

For citation

Zakharova AV, Vishnyakova AY, Detkov AA. Comparison of text classification models and methods. *RUDN Journal of Engineering Research*. 2025;26(3):298–309. (In Russ.) <http://doi.org/10.22363/2312-8143-2025-26-3-298-309>

Введение

В современном мире объем текстовой информации растет с каждым днем, и эффективная обработка данных становится одной из ключевых задач в различных областях, от бизнеса до науки. Инструменты, позволяющие извлекать полезную информацию из неструктурированных данных, таких как текстовые документы, статьи, новости и отзывы, становятся все более востребованными. Одним из ключевых процессов, используемых для решения таких задач, является классификация текстовых данных.

Классификация текста — это процесс автоматического распределения текстовых данных по заранее определенным категориям или классам на основе их содержания. Этот про-

цесс позволяет систематизировать информацию, облегчая ее поиск и анализ.

Процесс классификации текста обычно включает в себя три ключевых шага, каждый из которых в той или иной степени влияет на конечный результат. Подробнее эти этапы рассмотрены в теоретическом разделе данной работы.

Задачи исследования:

- формулировать, из каких шагов должен состоять оптимальный процесс предварительной обработки текстовых данных;
- определить модели представления текста, наиболее подходящие для решения задачи классификации текстовых данных;
- сравнить и выбрать наилучшие методы классификации текста.

1. Теоретические аспекты

1.1. Основные шаги предварительной обработки текстовых данных

Для работы с текстами на естественном языке (Natural Language Processing, NLP) необходима предварительная обработка, поскольку алгоритмы машинного обучения не способны работать с такими данными.

Предобработка текста, позволяющая компьютерам понимать и интерпретировать человеческий язык в полезный и значимый формат, включает в себя несколько этапов, которые могут отличаться в зависимости от задачи. Далее перечислим основные из них:

- **Нормализация** — этап, позволяющий исключить из текста шумовую информацию, в результате которого тексты приводятся к нужному регистру (зачастую к нижнему), удаляются знаки препинания, цифры и прочие небуквенные символы.

- **Токенизация** – процесс разбиения текста на отдельные элементы, называемые токенами и представляющие собой слова/фразы/символы/предложения (в зависимости от конкретной задачи и подхода к токенизации) [1].

- **Удаление стоп-слов**, т.е. слов, не несущих смысловой нагрузки. К ним можно отнести частицы, предлоги, союзы и т.п. Такие слова часто встречаются в текстах и обеспечивают связность предложений, однако при машинной обработке естественного языка являются шумом [2].

- **Стемминг** — метод нормализации токенов, в ходе которого от слов отсекаются префиксы, суффиксы и окончания, в результате чего выделяется основа слова [2]. Цель стемминга заключается в том, чтобы свести различные формы одного и того же слова к единой и базовой, что позволяет упростить анализ текста и уменьшить размер словаря.

- **Лемматизация** (альтернатива стемминга) — метод, основная идея которого заклю-

чается в том, чтобы привести слова к словарной форме, называемой «лемма» [3]. Лемматизация более тонкий процесс, использующий словарь и морфологический анализ [1]. В отличие от стемминга, который просто удаляет окончания и суффиксы, лемматизация учитывает грамматические правила и контекст, чтобы определить правильную лемму для данного слова.

1.2. Ключевые модели представления данных

Текст нельзя напрямую подать на вход модели машинного обучения, его надо сначала перевести в цифровой формат. Этот шаг называют представлением текста. Современные модели опираются на эмбединги (или векторные представления) — способ представления слов, фраз или других объектов в виде числовых векторов в многомерном пространстве. Такой подход позволяет захватывать семантические и синтаксические свойства языка¹.

К наиболее известным моделям векторизации текста с использованием эмбедингов, которые чаще всего встречаются в научных исследованиях по классификации текста, можно отнести следующие:

- **Word2Vec (Word to Vector)** — подход, основанный на численном представлении слов, сохраняющих контекстную близость (семантическую связь). Согласно алгоритму: слова, часто встречающиеся в тексте с одинаковыми словами, имеют близкие (по косинусному расстоянию) векторы [4].

- **GloVe (Global Vectors for Word Representation)** — подход, опирающийся на глобальные статистики, в качестве которых берется вероятность совместного появления слов в документах. Основная его идея состоит в том, чтобы извлечь семантические отношения между словами используя матрицу совместного использования [5].

Оба подхода относят к группе методов, которые используют статические эмбединги, представляющие каждое слово одним и тем же

¹ Классификация документов: 7 практических подходов для небольших наборов данных // Хабр: [сайт]. URL: <https://habr.com/ru/articles/504744/> (дата обращения: 19.01.2025).

вектором независимо от окружения. Значительным достижением в области NLP является возможность кодирования многозначных (или полисемичных) слов разными векторами в зависимости от контекста, в котором они используются. Это достигается благодаря контекстуальным эмбедингам, которые создаются трансформерными моделями. К таким моделям относится, например, BERT (Bidirectional Encoder Representations from Transformers) и GPT (Generative Pre-trained Transformer) [6].

1.3. Методы, используемые при классификации текстов

Методы, которые используются для решения задачи классификации текста, можно разделить на три основные группы:

- 1) машинные методы;
- 2) нейросетевые методы;
- 3) методы на основе трансформеров.

В табл. 1 отображены часто встречающиеся в научных исследованиях методы автоматической классификации текстовых данных.

Таблица 1

Обзор методов, используемых при классификации текста

№	Метод	Обозначение	Группа	Описание метода
1	Наивный байесовский метод	NB	1	Основывается на теореме Байеса с предположением о независимости признаков и позволяет определить класс объекта, опираясь на предшествующее распределение вероятности [4]. Хорошо работает с текстовыми данными и задачами, где требуется быстрая классификация
2	Дерево решений	DT	1	Использует древовидную структуру для принятия решений на основе значений признаков. Каждый узел дерева представляет собой вопрос о значении признака, а ветви — возможные ответы [7]. Деревья легко интерпретируемы, но могут быть подвержены переобучению
3	Случайный лес	RF	1	Строит множество деревьев решений и объединяет их результаты для улучшения точности и устойчивости модели. Использует случайную выборку подмножеств данных и признаков для создания каждого дерева, что помогает избежать переобучения и повышает обобщающую способность [8]
4	Логистическая регрессия	LR	1	Моделирует вероятность принадлежности объекта к классу, используя логистическую функцию [1]. Подходит для задач, где зависимая переменная является категориальной и позволяет интерпретировать коэффициенты как влияние предикторов на вероятность события
5	Метод k-ближайших соседей	KNN	1	Определяет класс объекта на основе классов его k-ближайших соседей в пространстве признаков [4]. Прост в реализации и не требует обучения, но может быть чувствителен к шуму и требует значительных вычислительных ресурсов при больших объемах данных
6	Метод опорных векторов	SVM	1	Ищет гиперплоскость, максимально разделяющую классы в пространстве признаков [8]. Может использовать различные ядра для обработки нелинейных данных и хорошо работает в высокоразмерных пространствах, но может быть чувствителен к выбору параметров и требует тщательной настройки
7	Многослойные перцептроны	MLP	2	Состоит из одного или нескольких скрытых слоев, которые обрабатывают входные данные и передают их на выходной слой. Каждый нейрон в слое связан с нейронами следующего слоя, и обучение происходит с использованием алгоритма обратного распространения ошибки [1]
8	Рекуррентные нейронные сети	RNN	2	Предназначен для обработки последовательных данных, таких как текст или временные ряды. RNN имеют циклические связи, что позволяет сохранять информацию о предыдущих состояниях и учитывать контекст [1]. Однако, могут страдать от проблемы затухающего градиента, что затрудняет обучение на длинных последовательностях
9	Сверточные нейронные сети	CNN	2	Обучаются распознавать признаки во входных данных с использованием сверточных слоев, после чего вычисленные признаки передаются в полносвязную сеть. Для решения задач, которые связаны с обработкой последовательностей, вместо двумерных сверток используются одномерные [1]

Окончание табл. 1

10	BERT	BERT	3	Обучается на задаче Masked Language Model (MLM), где некоторые слова в предложении замещаются масками, и модель предсказывает их [1]. Учитывает контекст как слева, так и справа от слова, что позволяет лучше понимать значение слов в зависимости от их окружения
11	SciBERT	SciBERT	3	Использует корпус научных публикаций для улучшения производительности в задачах, связанных с научной терминологией и контекстом [9]. Применяет тот же подход, что и BERT, но с учетом специфики научного языка, что делает ее особенно полезной для задач, таких как извлечение информации из научных статей, классификация и анализ текстов в области науки
12	RoBERTa	RoBERTa	3	Оптимизирует процесс предобучения BERT, используя более крупные объемы данных, более длительное время обучения и различные изменения в архитектуре. Демонстрирует лучшие результаты на многих задачах NLP по сравнению с оригинальным BERT, благодаря более эффективному обучению и более глубокому пониманию контекста [10]
13	T5	T5	3	Преобразует все задачи NLP в формат «текст в текст» — это означает, что как входные данные, так и выходные данные представлены в виде текста, что позволяет использовать одну и ту же архитектуру для различных задач, таких как перевод, суммирование, классификация и генерация текста [11]

Источники: выполнено А.В. Захаровой

Table 1

Overview of the methods used in text classification

№	Method	Designation	Group	Method description
1	Naive Bayes classifier	NB	1	This approach is founded on Bayes' theorem, operating under the assumption of feature independence. It facilitates the determination of an object's class based on its prior probability distribution [4]. It is well-suited for text data and tasks that require rapid classification
2	Decision tree	DT	1	It employs a tree structure to make decisions based on feature values. Each node of the tree represents a question regarding the meaning of a feature, and the branches represent possible answers [7]. Trees are easily interpretable but may be susceptible to overfitting
3	Random Forest	RF	1	It creates multiple decision trees and combines their results to improve the accuracy and stability of the model. The approach involves a random selection of subsets of data and features to create each tree, which helps to avoid overfitting and increases generalizing ability [8]
4	Logistic regression	LR	1	This approach utilizes a logistic function to simulate the probability of an object belonging to a given class [1]. This is an appropriate solution for situations in which the dependent variable is categorical. It allows for the interpretation of coefficients as the influence of predictors on the probability of an event
5	K-nearest neighbor algorithm	KNN	1	This method utilizes the classes of its k-nearest neighbors in the feature space to define the class of an object [4]. The implementation of this system is straightforward and does not require specialized training. However, it is sensitive to noise and requires substantial computing resources for effective operation, particularly when dealing with large volumes of data
6	Support vector machine	SVM	1	It looks for a hyperplane that maximizes the separation of classes in the feature space [8]. The method utilizes multiple cores to process non-linear data and functions effectively in high-dimensional spaces. However, it is susceptible to parameter selection and requires thorough configuration
7	Multilayer perceptron	MLP	2	It consists of one or more hidden layers that process the input data and transmit it to the output layer. Each neuron in a layer is connected to the neurons of the subsequent layer, and learning is enabled by the error backpropagation algorithm [1]
8	Recurrent neural network	RNN	2	It is designed to process sequential data, such as text or time series. These systems have a cyclical relationship, which allows for the storage of information about previous states and the consideration of context [1]. They may experience a decaying gradient issue, which can hinder learning effectiveness on long sequences

Ending of the Table 1

9	Convolutional neural network	CNN	2	The model is trained to recognize features in the input data using convolutional layers. The calculated features are then transmitted to a fully connected network. To solve problems related to sequence processing, one-dimensional convolutions are used instead of two-dimensional convolutions [1]
10	BERT	BERT	3	It is trained on the Masked Language Model (XML) task, where some words in a sentence are replaced by masks, and the model predicts them [1]. It considers the context both to the left and to the right of the word, which allows you to better understand the meaning of words depending on their environment
11	SciBERT	SciBERT	3	This tool utilizes the extensive collection of scientific publications to enhance productivity in tasks related to scientific terminology and context [9]. The model employs a similar approach to BERT, but it is tailored to the nuances of scientific language. This makes it particularly well-suited for tasks such as extracting information from scientific articles, classifying and analyzing texts in the scientific field
12	RoBERTa	RoBERTa	3	It optimizes the BERT retraining process by leveraging larger data sets, extended training times, and diverse architectural modifications. This model has been shown to achieve superior outcomes in numerous NLP applications when compared to the original BERT model. This enhancement can be attributed to its more effective training methods and a more profound understanding of the context [10]
13	T5	T5	3	It converts all NLP tasks into a text-to-text format, ensuring that both input and output data are presented as text. This allows for the use of a common architecture for various tasks, such as translation, summation, classification, and text generation [11]

Source: by A.V. Zakharova

2. Результаты и обсуждение

Для определения наилучшего метода были изучены научные статьи по теме автоматической классификации текста за последние 4 года. На основании результатов исследований, а именно значений показателя F1, были сформированы сводные таблицы для машинных

(табл. 2), нейросетевых (табл. 3) и трансформерных методов (табл. 4).

Из табл. 2 видно, что наивысшее значение показателя F1 соответствует LR и примерно равняется 82,2 %.

Из табл. 3 видно, что наивысшее значение показателя F1 соответствует CNN и равняется примерно 85,6 %.

Таблица 2

Результаты исследований машинных методов классификации текста, %

Исследование	Метод					
	KNN	DT	NB	RF	SVM	LR
Бобина Т.С. [12]	–	–	53,7	72	–	69,8
Гальченко Ю.В. [13]	–	–	80,6	–	–	89,8
Иномов Б.Б. [14]	70,3	65,6	–	63,8	–	81,8
Кусакин И.К. [15]	–	–	–	80,6	80,8	79,8
Минаев В.А. [16]	–	–	85,4	–	87,5	87,4
Мотовских Л.В. [17]	–	–	–	86	–	–
Мотовских Л.В. [18]	–	–	–	–	60	–
Плешакова Е.С., Гатауллин С.Т., Осипов А.В., Романова Е.В., Самбуrow Н.С. [19]	2	70	65	75	88	77 %
Рашитов Т.Ф. [20]	–	–	–	72,7	–	–
Челышев Э.А., Оцоков Ш.А., Раскатова М.В., Щёголев П. [21]	–	–	75 %	88	–	90
Среднее значение	49,7	67,8	71,9	76,9	79,1	82,2

Источник: выполнено А.В. Захаровой

Table 2

Results of research on machine methods of text classification, %

Research	Method					
	KNN	DT	NB	RF	SVM	LR
Bobina T.S. [12]	–	–	53.7	72	–	69.8
Galchenko Y.V. [13]	–	–	80.6	–	–	89.8
Inomov B.B. [14]	70.3	65.6	–	63.8	–	81.8
Kusakin I.K. [15]	–	–	–	80.6	80.8	79.8
Minaev V.A. [16]	–	–	85.4	–	87.5	87.4
Motovskikh L.V. [17]	–	–	–	86	–	–
Motovskikh L.V. [18]	–	–	–	–	60	–
Pleshakova E.S., Gataullin S.T., Osipov A.V., Romanova E.V., Samburov N.S. [19]	29	70	65	75	88	77
Rashitov T.F. [20]	–	–	–	72.7	–	–
Chelyshev E.A., Otsokov S.A., Raskatova M.V., Shchegolev P. [21]	–	–	75	88	–	90
The average value	49.7	67.8	71.9	76.9	79.1	82.2

Source: by A.V. Zakharova

Таблица 3

Результаты исследований нейросетевых методов классификации текста, %

Исследование	Метод		
	MLP	RNN	CNN
Бобина Т.С. [12]	70	68,2	–
Внуков И.А. [22]	78,4	75,8	82,3
Гальченко Ю.В. [13]	–	89,2	–
Иномов Б.Б. [14]	81,5	–	–
Куликов А.А. [23]	–	92,5	–
Кусакин И.К. [15]	75	84,5	–
Минаев В.А. [16]	–	89,7	89,6
Нежников Р.И. [10]	–	83,5	85
Плешакова Е.С., Гатауллин С.Т., Осипов А.В., Романова Е.В., Самбуров Н.С. [19]	79	–	–
Среднее значение	76,8	83,3	85,6

Источники: выполнено А.В. Захаровой

Table 3

Results of research on neural network methods of text classification, %

Research	Method		
	MLP	RNN	CNN
Bobina T.S. [12]	70	68.2	–
Nepotes I.A. [22]	78.4	75.8	82.3
Galchenko Yu.V. [13]	–	89.2	–
Inomov B.B. [14]	81.5	–	–
Kulikov A.A. [23]	–	92.5	–
Kusakin I.K. [15]	75	84.5	–
Minaev V.A. [16]	–	89.7	89.6
Nezhnikov R.I. [10]	–	83.5	85
Pleshakova E.S., Gataullin S.T., Osipov A.V., Romanova E.V., Samburov N.S. [19]	79	–	–
The average value	76.8	83.3	85.6

Source: by A.V. Zakharova

Таблица 4

Результаты исследований методов классификации текста на основе трансформеров, %

Исследование	Метод			
	SciBERT	BERT	T5	RoBERTa
Бондаренко В.И. [9]	71,6	64,8	–	–
Внуков И.А., Филиппов Ф.В. [22]	–	75,7	–	–
Кусакин И.К. [15]	–	86,5	–	–
Нежников Р.И. [10]	–	90	–	92,5
Прошина М.В. [11]	–	69	78	90
Среднее значение	71,6	77,2	78	91,3

Источник: выполнено А.В. Захаровой

Table 4

Results of research on text classification methods based on transformers, %

Research	Method			
	SciBERT	BERT	T5	RoBERTa
Bondarenko V.I. [9]	71.6	64.8	–	–
Vnukov I.A., Philippov F.V. [22]	–	75.7	–	–
Kusakin I.K. [15]	–	86.5	–	–
Nezhnikov R.I. [10]	–	90	–	92.5
Proshina M.V. [11]	–	69	78	90
The average value	71.6	77.2	78	91.3

Source: by A.V. Zakharova

Из табл. 4 видно, что наивысшее значение показателя F1 соответствует улучшенной версии модели BERT — RoBERTa и примерно равно 91,3. Однако следует отметить, что по методам на основе трансформеров было рассмотрено меньше исследований, что свидетельствует о менее точных средних значениях показателя F1.

Таким образом, если рассматривать по отдельности группы методов автоматической классификации текстовых данных, можно выделить наиболее точные:

- среди машинных методов наилучшим является логистическая регрессия ($F1_{LR} \approx 82,2$);
- среди нейросетевых методов наилучший — это сверточные нейронные сети ($F1_{CNN} \approx 85,6$);
- среди методов на основе трансформеров наилучшим является RoBERTa ($F1_{RoBERTa} \approx 91,3$).

Заключение

На основании изученных научных исследований по теме автоматической классификации текста можно сделать следующие выводы:

1. Оптимальный процесс предобработки данных для решения задачи классификации текста состоит из нескольких шагов и включает в себя как минимум нормализацию, токенизацию, удаление стоп-слов и стемминг/лемматизацию. Однако в зависимости от конкретной задачи эти шаги могут быть скорректированы.

2. Для перевода текста в цифровой формат лучше выбирать BERT, так как эта модель использует двунаправленный контекст и демонстрирует высокую точность в различных задачах NLP. Если ресурсы ограничены, можно рассматривать GPT как альтернативу, но эта модель больше ориентирована на генерацию текста, поэтому менее эффективна для задач, требующих глубокого понимания контекста. Word2Vec и GloVe могут быть использованы в менее сложных задачах, где контекст не так критичен.

3. Наилучшими методами автоматической классификации текста являются метод логистической регрессии, сверточные нейронные сети и RoBERTa. Точность каждого из них превышает 82, что является достаточно хорошим

результатом, поэтому все эти методы могут рассматриваться при решении уже конкретных задач:

– LR больше подходит для простых задач и небольших наборов данных;

– CNN и RoBERTa могут использоваться для сложных текстов и больших наборов данных, выбор зависит от доступности ресурсов и требований к точности.

Список литературы

1. *Логунова Т.В., Щербакова Л.В., Васюков В.М., Шимкун В.В.* Анализ алгоритмов классификации текстов // *Universum: технические науки*. 2023. № 2 (107). С. 4–20. <https://doi.org/10.32743/UniTech.2023.107.2.15064> EDN: MYDAJG
2. *Чельшев Э.А., Оцоков Ш.А., Раскатова М.В.* Автоматическая рубрикация текстов с использованием алгоритмов машинного обучения // *Вестник Российского нового университета. Серия: Сложные системы: модели, анализ и управление*. 2021. № 4. С. 175–182. <https://doi.org/10.18137/RNU.V9187.21.04.P.175> EDN: SBCVLA
3. *Акжолов Р.К., Верига А.В.* Предобработка текста для решения задач NLP // *НИЦ Вестник науки*. 2020. № 3 (24) Т. 1. С. 66–68. EDN: KCGMUZ
4. *Максютин П.А., Шульженко С.Н.* Обзор методов классификации текстов с помощью машинного обучения // *Инженерный вестник Дона*. 2022. № 12 (96). С. 1–9. EDN: USWOAI
5. *Pennington J., Socher R., Manning D. Christopher.* GloVe: Global Vectors for Word Representation. URL: <https://nlp.stanford.edu/pubs/glove.pdf> с.3 (Дата обращения: 20.01.2025)
6. *Жусип М.Н., Жаксыбаев Д.О.* Сравнение чат-ботов с использованием трансформеров и нейросетей: исследование применения архитектур GPT и BERT // *НИЦ Вестник науки*. 2024. № 9 (78) Т. 2. С. 287–290. EDN: DEXNMS
7. *Батура Т.В.* Методы автоматической классификации текстов // *Международный журнал «Программные продукты и системы»*. 2017. Т. 30. № 1. С. 85–99. EDN: ZDUXCL
8. *Буйлова Н.Н.* Классификация текстов по жанрам с помощью алгоритмов машинного обучения // *Научно-техническая информация. Серия 2. Информационные процессы и системы*. 2018. № 8. С. 34–38. EDN: XYBWQP
9. *Бондаренко В.И.* Классификация научных текстов с помощью методов глубокого машинного обучения // *Вестник Донецкого национального университета. Серия Г: Технические науки*. 2021. № 3. С. 69–77. EDN: FJPQFE
10. *Нежников Р.И., Марьенков А.Н.* Сравнительный анализ моделей трансформера для классификации неструктурированной текстовой информации // *Прикаспийский журнал: управление и высокие технологии*. 2024. № 2 (66). С. 32–38. EDN: LREEXX
11. *Прошина М.В., Виноградов А.Н.* Анализ эффективности трансформеров для решения некоторых задач NLP // *Информационно-телекоммуникационные технологии и математическое моделирование высокотехнологичных систем : материалы Всероссийской конференции с международным участием, Москва, 17–21 апреля 2023 года. Москва: Российский университет дружбы народов (РУДН), 2023. С. 153–157. EDN: RXMCCJ*
12. *Бобина Т.С.* Автоматическая классификация текста при помощи методов машинного обучения и нейронных сетей // *Современные информационные технологии в образовании, науке и промышленности : сборник трудов. XXVIII Международная конференция. XXVI Международный конкурс научных и научно-методических работ. Всероссийский конкурс проектов «Научное творческое сообщество», Мытищи, Москва, 25–26 апреля 2024 года. Москва : Экон-Информ, 2024. С. 253–258. EDN: PMVINH*
13. *Гальченко Ю.В., Нестеров С.А.* Классификация текстов по тональности методами машинного обучения // *Системный анализ в проектировании и управлении : сборник научных трудов XXVI Международной научно-практической конференции : в 3 частях. Санкт-Петербург, 13–14 октября 2022 года. Т. Часть 3. Санкт-Петербург : Санкт-Петербургский политехнический университет Петра Великого, 2023. С. 369–378. <https://doi.org/10.18720/SPBPU/2/id23-501> EDN: YURQCU*
14. *Иномов Б.Б., Тропманн-Фрик М.* Классификация научных текстов по специальностям методами машинного обучения // *Вестник Новосибирского государственного университета. Серия: Информационные технологии*. 2022. Т. 20. № 2. С. 27–36. <https://doi.org/10.25205/1818-7900-2022-20-2-27-36> EDN: ORMRLC
15. *Кусакин И.К., Федорец О.В., Романов А.Ю.* Исследование методов машинного обучения для классификации научных текстов на русском языке // *Научно-техническая информация. Серия 2: Информационные процессы и системы*. 2022. № 12. С. 6–9. <https://doi.org/10.36535/0548-0027-2022-12-2> EDN: EPASJQ
16. *Минаев В.А., Поликарпов Е.С., Симонов А.В.* Применение глубинных нейронных сетей для выявления деструктивного контента в социальных медиа // *Информация и безопасность*. 2021. Т. 24. № 3. С. 361–372 <https://doi.org/10.36622/VSTU.2021.24.3.004> EDN: IMHBIG

17. Мотовских Л.В. Классификация медиатекстов с использованием машинного обучения // Вестник Московского государственного лингвистического университета. Гуманитарные науки. 2020. № 12 (841). С. 124–130. EDN: YZFGJN

18. Мотовских Л.В. Автоматическая классификация текстов различных СМИ // Collegium Linguisticum–2021 : сборник научных статей ежегодной конференции Студенческого научного общества МГЛУ, Москва, 17–19 марта 2021 года. Москва : Московский государственный лингвистический университет, 2021. С. 83–88. EDN: LGMFHK

19. Плешакова Е.С., Гатауллин С.Т., Осипов А.В., Романова Е.В., Самбуров Н.С. Эффективная классификация текстов на естественном языке и определение тональности речи с использованием выбранных методов машинного обучения // Вопросы безопасности. 2022. № 4. С. 1–14. <https://doi.org/10.25136/2409-7543.2022.4.38658> EDN: UPWMCV

20. Рашитов Т.Ф., Квасов М.Н. Использование метода машинного обучения «Случайный лес» для классификации текстов по рубрикам // Состояние и перспективы развития современной науки по направлению «АСУ, информационно-телекоммуникационные системы» : сборник статей III Всероссийской научно-технической конференции, Анапа, 22–23 апреля 2021 года. Том 2. Анапа : Федеральное государственное автономное учреждение «Военный инновационный технополис “ЭРА”», 2021. С. 76–78. EDN: QTEYUB

21. Чельшев Э.А., Оцоков Ш.А., Раскатова М.В., Щёголев П. Сравнение методов классификации русскоязычных новостных текстов с использованием алгоритмов машинного обучения // Вестник кибернетики. 2022. № 1 (45). С. 63–71. <https://doi.org/10.34822/1999-7604-2022-1-63-71> EDN: VHTYBV

22. Внуков И.А., Филиппов Ф.В. Средства глубокого обучения для классификации новостных текстов в интеллектуальных рекомендательных системах // Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2024) : материалы XIII Международной научно-технической и научно-методической конференции, Санкт-Петербург, 27–28 февраля 2024 года. Санкт-Петербург : Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, 2024. С. 190–194. EDN: EWPVOP

23. Куликов А.А., Маляев Э.К. Сравнение архитектур рекуррентных нейронных сетей в задаче бинарной классификации текстов // Инновационное развитие техники и технологий в промышленности (ИНТЕКС-2021) : сборник материалов Всероссийской научной конференции молодых исследователей с международным участием, Москва, 12–15 апреля 2021 года.

Часть 3. Москва : Российский государственный университет имени А.Н. Косыгина (Технологии. Дизайн. Искусство), 2021. С. 223–226. EDN: XQKUNP

References

1. Logunova TV, Shcherbakova LV, Vasyukov VM, Shimkun VV. Analysis textus classificationis algorithmorum. *Universi: scientiarum technicarum: electronic scientiae acta*. 2023;(2):4–20. (In Russ.) <https://doi.org/10.32743/UniTech.2023.107.2.15064> EDN: MYDAJG

2. Chelyshev EA, Otsokov SA, Raskatova MV. Automatic textus rubricationis utens machina algorithms discendi. *Bulletin Novae universitatis russicae. Series: Systemata Complexa: exempla, analysis et administratio*. 2021;(4):175–182. (In Russ.) <https://doi.org/10.18137/RNU.V9I87.21.04.P.175> EDN: SBCVLA

3. Akzholov RK, Veriga AV. Textus praeprocessing ad SOLVENDAS NLP difficultates. *Sic Bulletin Scientiae*. 2020;(3):66–68. (In Russ.) EDN: KCGMUZ

4. Maksyutin PA, Shulzhenko SN. Recensio textuum methodorum classificationis utens machina discendi. *Ipsium Bulletin De Don*. 2022;(12):1–9. (In Russ.) EDN: USWOAI

5. Pennington J, Socher R, Manning D. *Christopher GloVe: Global Vectors for Word Representation*. Available from: <https://nlp.stanford.edu/pubs/glove.pdf> c.3 (accessed: 20.01.2025)

6. Zhusip MN, Zhaksybaev DO. Comparatio chatbotorum utens transformatoribus et reticulis neuralis: studium applicationis GPT et BERT architecturae. *Sic Bulletin Scientiae*. 2024;(9):287–290. (In Russ.) EDN: DEXNMS

7. Batura TV. Methodi textus classificationis latae. *Acta Internationalis Productorum Et Systematum Programmatum*. 2017;30(1):85–99. (In Russ.) EDN: ZDUXCL

8. Bulova NN. Classificatio textuum per genus machinae algorithmorum discendi utens. *Scientifica et technica notitia 2: Processiones Et dispositiones*. 2018;(8):34–38. (In Russ.) EDN: XYBWQP

9. Bondarenko VI. Classificatio textuum scientiarum utens machinae altae methodi discendi. *Bulletin Universitatis Nationalis Donetsk. Series G: Scientiarum Technicarum*. 2021;(3):69–77. EDN: FJPQFE

10. Nezhnikov RI, Marienkov AN. Analysis Comparativa transformatoris exemplorum pro classificatione informationis textualis. *Acta Caspiae: Administratio et Technologiae Altae*. 2024;(2):32–38. (In Russ.) EDN: LREEXX

11. Proshina MV, Vinogradov AN. Analysis efficiaciae transformatorum ad solvendas QUASDAM DIFFICULTATES NLP. *Informationes et technologiae telecommunicationis et mathematicae exemplaris systematum summus technicorum: acta Colloquii Omnium russorum Cum Participatione Internationali, Moscow,*

17–21 aprilis 2023. Moscow: RUDN University; 2023; 153–157. (In Russ.) EDN: RXMCCJ

12. Bobina TS. Automatic textus Classificationis utens machinae methodi discendi et retiacula neuralis. *Moderna informationes technologiae in educatione, scientia et industria: Acta. Colloquium Internationale 28th. 26th Competition internationalis operum scientificorum et emendationum. Omnes-Russian Project Competition "Communitas Creatrix Scientifica" Mytishchi, Moscow, 25–26 Aprilis, 2024*. Moscow: Limitata Rusticis Company "Ekon-Certioem Libellorum Domus;" 2024:253–258. (In Russ.) EDN: PMVIHF

13. Galchenko YV, Nesterov SA. Classificatio textuum per tonalitem machinae methodi discendi. *Systematis analysi in consilio et administratione: acta 26th Conferentiae Scientifica Et Practicae Internationalis. Ad 3 a. m., Saint Petersburg, 13–14 octobris, 2022. Part 3*. Saint Petersburg: Petrus Magnus S. Petersburg Universitas Polytechnica; 2023. P. 369–378. (In Russ.) <https://doi.org/10.18720/SPBPU/2/id23-501> EDN: YURQCU

14. Inomov BB, Tropmann-Frick M. Classificatio textuum scientificorum a propriis utens machinae methodi discendi. *Bulletin Novosibirsk Universitatis Publicae. Series: Informationis Technicae*. 2022;(2):27–36. (In Russ.) <https://doi.org/10.25205/1818-7900-2022-20-2-27-36> EDN: ORMRL

15. Kusakin IK, Fedorets OV, Romanov AY. Investigatio machinae methodi discendi ad digerendos textus scientificos in Notitia russica. *Scientifica et Technica. 2: Processiones Et dispositiones*. 2022;(12):6–9. (In Russ.) <https://doi.org/10.36535/0548-0027-2022-12-2> EDN: EPASJQ

16. Minaev VA, Polikarpov ES, Simonov AV. Usus reticulorum neuralium profundorum ad cognoscendum contentum perniciosum in instrumentis socialibus. *Informationibus et Securitate*. 2021;(3):361–372. (In Russ.) <https://doi.org/10.36622/VSTU.2021.24.3.004> EDN: IMHBIG

17. Motovskikh LV. Classificatio textuum instrumentorum utens machina discendi. *Bulletin Universitatis Linguisticae Civitatis Moscuae. Humanas*. 2020;(12):124–130. (In Russ.) EDN: YZFGJN

18. Motovskikh LV. Classificatio Latae textuum variarum instrumentorum. *Collegium Linguisticum-2021: Collectio articulorum scientificorum annui conferentiae*

Mglu Studentium Societatis Scientificaе, Moscow, martii 17–19, 2021. Moscow: State Linguistic University; 2021: 83–88. (In Russ.) EDN: LGMFHK

19. Pleshakova ES, Gataullin ST, Osipov AV, Romanova EV, Samburov NS. Efficax classificatio textuum in lingua naturali et determinatio loquelaе tonality utens delectae machinae discendi methodos. *Quaestiones Securitatіs*. 2022;(4):1–14. (In Russ.) <https://doi.org/10.25136/2409-7543.2022.4.38658> EDN: UPWMCV

20. Rashitov TF, Kvasov MN. Usus machinae "Temere Silvae" methodus discendi ad textus digerendos per capita. *Statum et spem evolutionis scientiae modernaе in agro automated systemata moderandi, informationes et systemata telecommunicationis: Collectio articulorum III Conferentiae Scientificaе et Technicae Omnes-russicae, Anapa, 22–23 aprilis 2021. 2 volumine*. Anapa: Status Foederalis Institutio Sui Iuris "Innovatio Militaris Technopolis ERA." 2021;76–78. (In Russ.) EDN: QTEYUB

21. Chelyshev EA, Otsokov SA, Raskatova MV, Shchegolev P. Comparatio methodorum classificationis de textibus nuntiorum russorum linguarum utentes machinae algorithmorū discendi. *Bulletin Cyberneticorum*. 2022;(1):63–71. (In Russ.) <https://doi.org/10.34822/1999-7604-2022-1-63-71> EDN: VHTYBB

22. Vnukov IA, Philippov FV. Alta discendi instrumenta ad digerendos nuntios textus in intelligentibus commendatione systemata. *Actualia problemata communicationum infotelec in scientia et educatione (APINO 2024): Acta XIII Conferentiae Scientificaе Internationalis, Technicae Et Scientificaе Methodologicae, Saint Petersburg, 27–28 februarii, 2024*. Saint Petersburg: Universitas Civitatis S. Petersburg Telecommunicationum ex nomine nuncupatur Professor M.A. Bonch-Bruevich. 2024: 190–194. (In Russ.) EDN: EWPVOP

23. Kulikov AA, Mailyan E.K. Comparatio architecturae retis neuralis recurrentis in problemate textus classificationis binarii. *Innovative evolutionis machinationis et technologiae in industria (INTEX-2021): Acta Omnium-russorum Conferentiae Scientificaе Inquisitorum Iuvenum Cum Participatione Internationali, Moscow, 12–15 aprilis 2021. Pars 3 Volumine*. Moscow: A.N. Kosygin Universitas Civitatis russicae (Technologia. Consilio. Ars). (In Russ.) EDN: XQKUHP

Сведения об авторах

Захарова Ангелина Валерьевна, магистрант кафедры анализа систем и принятия решений, Уральский федеральный университет им. Первого Президента России Б.Н. Ельцина (УрФУ), Российская Федерация, 620062, г. Екатеринбург, ул. Мира, д. 19; eLIBRARY SPIN-код: 6278-8518, ORCID: 0009-0007-9651-4530; e-mail: zakharova.linusha@mail.ru

Вишнякова Алина Юрьевна, старший преподаватель, аспирант кафедры анализа систем и принятия решений, Уральский федеральный университет им. Первого Президента России Б.Н. Ельцина (УрФУ), Российская Федерация, 620062, г. Екатеринбург, ул. Мира, д. 19; eLIBRARY SPIN-код: 5641-6945, ORCID: 0000-0003-1649-4167; e-mail: alina.vishniakova@urfu.ru

Детков Александр Александрович, кандидат экономических наук, доцент кафедры анализа систем и принятия решений, Уральский федеральный университет им. Первого Президента России Б.Н. Ельцина (УрФУ), Российская Федерация, 620062, г. Екатеринбург, ул. Мира, д.19; eLIBRARY SPIN-код: 5310-3027, ORCID: 0009-0003-3958-3549; e-mail: a.a.detkov@urfu.ru

About the authors

Angelina V. Zakharova, Master's student of the Department of Systems Analysis and Decision-making, Ural Federal University named after the first President of Russia B.N. Yeltsin, 19 Mira St, Yekaterinburg, 620062, Russian Federation; eLIBRARY SPIN-code: 6278-8518, ORCID: 0009-0007-9651-4530; e-mail: zakharova.linusha@mail.ru

Alina Yu. Vishnyakova, Senior Lecturer, Postgraduate Student of the Department of Systems Analysis and Decision-making, Ural Federal University named after the first President of Russia B.N. Yeltsin, 19 Mira St, Yekaterinburg, 620062, Russian Federation; eLIBRARY SPIN-code: 5641-6945, ORCID: 0000-0003-1649-4167; e-mail: alina.vishniakova@urfu.ru

Alexander A. Detkov, PhD in Economics, Associate Professor of the Department of Systems Analysis and Decision-Making, Ural Federal University named after the first President of Russia B.N. Yeltsin, 19 Mira St, Yekaterinburg, 620062, Russian Federation; eLIBRARY SPIN-code: 5310-3027, ORCID: 0009-0003-3958-3549; e-mail: a.a.detkov@urfu.ru



DOI: 10.22363/2312-8143-2025-26-3-310-322

EDN: AAMJLK

Research article / Научная статья

Prediction of Breast Cancer Using Machine Learning

Florence Uwingabiye^{ID}, Thadee Kimenyi^{ID}, Asaph Kimenyi^{ID}, Larisa V. Kruglova^{ID}

RUDN University, Moscow, Russian Federation

✉ cyizashem@gmail.com

Article history

Received: April 29, 2025

Revised: June 17, 2025

Accepted: July 12, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. Breast cancer remains one of the leading causes of morbidity and mortality among women worldwide. Despite the global emphasis on early detection, breast cancer continues to pose a significant public health challenge. The object of this study is to predict the breast cancer risk using various machine-learning approaches based on demographic, laboratory, and mammographic data. It employed a quantitative research design to assess the potential of machine learning (ML) in predicting breast cancer. It integrated supervised ML algorithms, including Support Vector Machines (SVM), Decision Trees, Random Forests, and Deep Learning models, to evaluate their accuracy, efficiency, and applicability in medical diagnostics. The dataset revealed significant variability in tumor features such as mean radius, mean texture, mean perimeter, and mean area. The target variable demonstrated a class imbalance, with 62% benign and 38% malignant cases. Among the evaluated models, Random Forest outperformed others with the highest accuracy, precision, recall, F1-score, and ROC-AUC, indicating superior predictive capability. The Logistic Regression and Support Vector Machine models showed competitive performance, particularly in precision and recall, while the Decision Tree model exhibited the lowest overall performance across metrics.

Keywords: early detection, public health, tumor, mammography, medical diagnostics, machine-learning algorithms

Authors' contribution

Uwingabiye F. — the concept of research; *Uwingabiye F.* and *Kimenyi T.* — data analysis and interpretation; *Kimenyi A.* — writing the text; *Kruglova L.V.* — editing and approval of the text of the manuscript. All authors read and approved the final version of the article.

For citation

Uwingabiye F, Kimenyi T, Kimenyi A, Kruglova LV. Prediction of breast cancer using machine learning. *RUDN Journal of Engineering Research*. 2025;26(3):310–322. <http://doi.org/10.22363/2312-8143-2025-26-3-310-322>



Прогнозирование рака груди с помощью машинного обучения

Ф. Увингабийе[✉], Т. Кимений[✉], А. Кимений[✉], Л.В. Круглова[✉]

Российский университет дружбы народов, Москва, Российская Федерация

✉ cyizashem@gmail.com

История статьи

Поступила в редакцию: 29 апреля 2025 г.

Доработана: 17 июня 2025 г.

Принята к публикации: 12 июля 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Рак молочной железы остается одной из основных причин заболеваемости и смертности среди женщин во всем мире. Несмотря на значительные усилия, направленные на раннее выявление болезни, рак молочной железы по-прежнему представляет собой серьезную проблему для здоровья населения. Цель исследования — прогнозирование риска рака молочной железы с использованием различных подходов машинного обучения, основанных на демографических, лабораторных и маммографических данных. Использована модель количественных оценок методов машинного обучения в прогнозировании рака молочной железы. Модель интегрирует алгоритмы машинного обучения, включая метод опорных векторов, деревья решений, случайные леса и модели глубокого обучения, для оценки их точности, эффективности и применимости в медицинской диагностике. Набор данных выявил значительную изменчивость в параметрах опухоли, таких как средний радиус, средняя текстура, средний периметр и средняя площадь. Целевая переменная продемонстрировала дисбаланс классов, с 62 % доброкачественных и 38 % злокачественных случаев. Среди оцененных моделей Random Forest превзошла другие по наибольшей точности, чувствительности, полноте, F1-мере и площади под кривой операционных характеристик, указывая на наилучшую способность прогнозирования. Модели логистической регрессии и метода опорных векторов показали конкурентоспособность, особенно почувствительности и полноте, в то время как модель дерева решений продемонстрировала самую низкую общую эффективность по всем показателям.

Ключевые слова: ранняя диагностика, общественное здравоохранение, опухоль, маммография, медицинская диагностика, алгоритмы машинного обучения

Вклад авторов

Увингабийе Ф. — разработка концепции исследования; Увингабийе Ф., Кимений Т. — анализ и интерпретация данных. Кимений А. — написание текста; Круглова Л.В. — редактирование и утверждение текста рукописи. Все авторы ознакомлены с окончательной версией статьи и одобрили ее.

Для цитирования

Uwingabiye F., Kimenyi T., Kimenyi A., Kruglova L.V. Prediction of breast cancer using machine learning // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 310–322. <http://doi.org/10.22363/2312-8143-2025-26-3-310-322>

Introduction

Breast cancer remains one of the leading causes of morbidity and mortality among women worldwide. In 2020, an estimated 2.3 million

women were diagnosed with breast cancer, making it the most prevalent cancer globally¹.

Despite advancements in medical technologies, early detection remains a critical challenge, as many cases are identified at advanced stages,

¹ WHO. Breast cancer: Early diagnosis and screening. Geneva: World Health Organization. 2021.

particularly in low-resource settings. This delay often leads to higher mortality rates, with breast cancer accounting for approximately 685 000 deaths in 2020 alone². The increasing burden of breast cancer underscores the need for innovative diagnostic solutions that can enhance early detection and improve survival rates.

Traditional diagnostic methods, such as mammography, clinical breast exams, and biopsies, play a pivotal role in detecting breast cancer. However, these approaches are often limited by human error, accessibility challenges, and high costs, particularly in low- and middle-income countries (LMICs). Studies have shown that mammography, while effective, has sensitivity rates ranging from 77 to 95% depending on patient age and breast density [1]. Furthermore, false positives and negatives can lead to unnecessary procedures or missed diagnoses, emphasizing the need for more accurate and efficient diagnostic systems.

In recent years, machine learning (ML) has emerged as a transformative tool in the medical field, offering promising solutions for breast cancer prediction. ML models, leveraging large datasets and advanced algorithms, have demonstrated superior performance in identifying early-stage cancers. For instance, deep learning models have achieved diagnostic accuracy rates of over 95% in distinguishing malignant from benign lesions [2]. By integrating ML into breast cancer diagnostics, healthcare systems have the potential to overcome existing barriers, improve early detection, and ultimately reduce global mortality rates.

By focusing on breast cancer, this article aims to develop a machine learning model capable of predicting breast cancer risk with high accuracy.

1. Background

Despite the global emphasis on early detection, breast cancer continues to pose a significant public health challenge. Traditional diagnostic methods, while valuable, are often constrained

by factors such as high costs, limited access in LMICs, and variability in interpretation by radiologists. These challenges contribute to delayed diagnoses, with up to 60% of breast cancer cases in developing countries detected at advanced stages³. This disparity highlights an urgent need for innovative approaches that are both accurate and accessible.

Machine learning has shown remarkable potential in transforming breast cancer diagnostics, yet its adoption faces significant barriers. Although ML models have demonstrated diagnostic accuracy rates exceeding those of traditional methods, their integration into healthcare systems remains limited. A lack of resources, technical expertise, and standardized implementation strategies impedes the use of ML, particularly in resource-constrained settings [3]. Furthermore, concerns about algorithmic bias and the reliability of AI-driven diagnostics contribute to skepticism among healthcare providers.

Given these challenges, the global healthcare community must address the gap between technological advancements and their practical application in breast cancer prediction. This study seeks to explore the potential of ML in overcoming these barriers, focusing on its accuracy, cost-effectiveness, and ability to improve early detection rates. By addressing these issues, the paper aims to contribute to the broader goal of reducing breast cancer mortality and enhancing healthcare outcomes worldwide.

Breast cancer prediction focuses on identifying individuals with the risk of the disease development or distinguishing between benign and malignant cases. Early and accurate prediction significantly improves treatment outcomes, as it allows for timely interventions and better management strategies [4]. The predictive process involves evaluating various factors, including genetic predispositions, lifestyle behaviors, and clinical markers, to assess the likelihood of developing breast cancer. For instance, mutations in the BRCA1 and BRCA2 genes are well-documented predictors

² Globocan. Global cancer statistics 2020. International Agency for Research on Cancer (IARC). 2020.

³ WHO. Breast cancer: Early diagnosis and screening. Geneva: World Health Organization. 2021.

of breast cancer risk, accounting for 5–10% of hereditary cases [5].

Additionally, predictive models often rely on epidemiological data, which include variables such as age, family history, and reproductive factors. However, these models can be limited by the complexity of cancer development, which involves interactions between genetic, environmental, and hormonal factors [6]. The integration of biomarkers, such as hormone receptor status (e.g., HER2, estrogen, and progesterone receptors), has enhanced prediction accuracy, but the reliance on laboratory-based tests creates barriers in resource-limited settings. Consequently, there is a growing emphasis on developing advanced and accessible predictive techniques.

The global rise in breast cancer incidence, with 2.3 million new cases reported in 2020, underscores the need for innovative prediction methods. Emerging technologies like artificial intelligence (AI) and machine learning are being increasingly explored to bridge the gaps in prediction accuracy and accessibility, particularly in LMICs. By leveraging large datasets and computational power, these methods aim to improve precision and reduce diagnostic disparities.

1.1. Rationale

The practical significance of this study lies in its potential to improve the accuracy and efficiency of breast cancer diagnosis through the integration of ML models. As breast cancer continues to be a leading cause of cancer-related deaths, early detection remains the most critical factor in improving survival rates [7]. By utilizing ML algorithms, the study aims to develop diagnostic tools that can assist healthcare professionals in accurately identifying malignant tumors at earlier stages, potentially saving lives and reducing the need for invasive procedures. ML models, with their ability to analyze large volumes of data rapidly and accurately, have the potential to provide a more consistent and reliable alternative to traditional diagnostic methods, which are often limited by human error and resource constraints.

Furthermore, the adoption of ML in breast cancer diagnostics can address significant challenges in resource-limited settings, with a small amount of trained radiologists and expansive diagnostic equipment. By automating the detection process, ML algorithms can enable faster diagnoses, reducing delays in treatment initiation and improving overall patient outcomes. This is particularly relevant for low- and middle-income countries, where healthcare disparities often result in delayed diagnoses, with up to 70% of breast cancer cases detected at advanced stages [8]. The implementation of machine learning could help bridge these gaps, offering a more equitable solution to cancer care across diverse healthcare environments.

Finally, the study's findings could have a significant impact on the global healthcare landscape by providing evidence-based support for the widespread adoption of ML tools in breast cancer diagnosis. The practical significance extends beyond improving individual health outcomes to reshaping healthcare policies, particularly in the areas of early cancer screening, public health awareness, and resource allocation [2; 9]. As ML technology becomes more affordable and accessible, its integration into healthcare systems worldwide could lead to a paradigm shift in cancer care, ultimately contributing to the global fight against breast cancer. Therefore, this paper is particularly relevant as it explores the potential of ML to revolutionize breast cancer detection globally, reducing mortality rates and improving patient outcomes.

1.2. Objectives

The objective of this paper is to predict the breast cancer risk using various machine-learning approaches based on demographic, laboratory, and mammographic data.

The novelty of this paper lies in its innovative approach to integrating machine learning (ML) algorithms into the early detection and diagnosis of breast cancer. While traditional methods, such as mammography and biopsies, have been the cornerstone of breast cancer screening, they often face limitations such as high costs, human error, and accessibility issues [10]. This paper introduces

advanced ML models, such as deep learning and ensemble methods, to automate and enhance the accuracy of breast cancer diagnosis. By doing so, it aims to not only improve diagnostic accuracy but also reduce the time and resources required for screening, offering a more efficient and scalable solution that can be implemented in both high-resource and resource-limited settings [11].

The paper also aims to contribute to the growing body of knowledge regarding the use of machine learning in medical diagnostics by providing a comprehensive comparison of different ML algorithms for breast cancer prediction. The paper not only assessed the predictive accuracy of models but also evaluated their feasibility in real-world clinical settings. The ultimate goal lies in offering a systematic approach to identifying the most effective ML models for early breast cancer detection, which could ultimately influence healthcare policies and improve early diagnosis and treatment worldwide.

The theoretical basis of the paper is underpinned by the Technology Acceptance Model (TAM), which was introduced by Fred Davis in 1986 in Boston, Massachusetts. This theory aims to explain how users come to accept and use technology, emphasizing two main factors: Perceived Usefulness (PU) and Perceived Ease of Use (PEOU). Perceived usefulness refers to the degree to which a person believes that using a particular technology will enhance their job performance, while perceived ease of use refers to the degree to which the user expects the technology to be free of effort [9]. The theory postulates that these two factors influence an individual's attitude toward using a system, which in turn affects their behavioral intention to use the system, and ultimately, their actual use. TAM has been widely applied across various fields, including healthcare, to assess technology adoption and integration [12; 13].

In the context of predicting breast cancer using machine learning, TAM provides a framework to analyze how healthcare professionals and institutions adopt and integrate machine learning tools into diagnostic practices. First, regarding the PU, healthcare providers may adopt machine

learning systems if they perceive that these tools can enhance diagnostic accuracy and efficiency. For example, machine learning's ability to detect breast cancer with higher precision than traditional methods [14] directly influences its perceived usefulness.

Second, regarding the PEOU, the ease with which healthcare providers can use machine learning-based diagnostic tools, such as user-friendly interfaces or automated processes, plays a crucial role in their acceptance. Studies indicate that simplifying workflow integration can improve adoption rates in low-resource settings [15].

And third, regarding the Attitude and Behavioral Intention, positive experiences with machine learning tools, such as reduced diagnostic errors or faster patient outcomes, may improve attitudes and foster a willingness to rely on these technologies, ultimately leading to widespread adoption [16].

Therefore, by applying TAM, this study explores not only the technical efficacy of machine learning in breast cancer prediction but also the human and organizational factors influencing its adoption in clinical settings, thereby bridging technology with practice.

2. Methodology

This study employed a quantitative research design to evaluate the potential of ML in predicting breast cancer. Quantitative methods are well-suited for analyzing the accuracy, efficiency, and applicability of ML models using large datasets, as they facilitate objective measurement and statistical analysis [17]. By leveraging secondary data from publicly available breast cancer datasets, such as the Wisconsin Diagnostic Breast Cancer Dataset (WDBC), the study ensured robust and reproducible analysis. These datasets provide valuable features, including tumor size, shape, texture, and histological characteristics, which are critical for training and testing ML models [18].

2.1. Machine Learning Algorithms

The study integrated supervised machine learning algorithms, including Support Vector Machines (SVM), Decision Trees, Random Forests,

and Deep Learning models. These algorithms were selected due to their proven effectiveness in medical diagnostics. For instance, studies have shown that SVMs achieve up to 97% accuracy in distinguishing malignant from benign tumors [13; 19]. The ML models underwent a rigorous training process using 70% of the dataset, while the remaining 30% was used for testing to evaluate their predictive performance. Key metrics, such as accuracy, sensitivity, specificity, and area under the receiver operating characteristic curve (AUC-ROC), was used to assess the models [20].

2.2. Cross-validation and cost-benefit analysis

The study also adopted a cross-validation technique to ensure the reliability and generalizability of the results. Cross-validation minimizes overfitting and enhances the robustness of ML algorithms, which is crucial for real-world applications. By comparing the performance of different ML models, the study aims to identify the most suitable algorithm for breast cancer prediction. Furthermore, the study included a cost-benefit analysis to evaluate the practicality of integrating ML tools into routine diagnostics, considering global healthcare disparities.

3. Implementation and Tools

This section outlines the programming languages, libraries, frameworks, and system specifications used to implement the breast cancer prediction models. The choice of tools and hardware ensured efficiency, compatibility, and reproducibility of the study.

Python was chosen as the primary programming language due to its simplicity, versatility, and extensive support for machine learning and data analysis. Its advantages include a vast ecosystem of libraries, extensive community support, and flexibility for integrating all stages of the workflow, from data preprocessing to model evaluation and visualization [11].

Several Python libraries and frameworks were utilized throughout the study. For machine learning tasks, Scikit-learn was employed to implement

algorithms such as Support Vector Machines, Random Forest, Logistic Regression, and K-Nearest Neighbors (KNN), as well as evaluation metrics like precision, recall, and ROC-AUC. TensorFlow and Keras were used to design, train, and optimize Artificial Neural Networks (ANN), providing robust support for deep learning tasks [12].

Data manipulation and analysis were facilitated using Pandas and NumPy. Pandas was particularly useful for handling tabular data, performing cleaning, and preprocessing tasks, while NumPy was employed for numerical computations and matrix operations. For visualization, Matplotlib and Seaborn were utilized. Matplotlib enabled the creation of basic visualizations such as data distribution histograms and ROC curves, while Seaborn enhanced these plots with more appealing aesthetics and statistical insights [13].

4. Recent Developments

Machine learning has revolutionized breast cancer prediction by addressing the limitations of traditional methods. ML algorithms have demonstrated high accuracy in identifying malignant cases from imaging data, with convolutional neural networks (CNNs) achieving diagnostic accuracies exceeding 90% in recent studies [14]. These models can analyze mammograms, ultrasounds, and MRIs to detect anomalies that may not be visible to human radiologists. For instance, a 2021 study found that ML models reduced false-positive rates by 20% compared to traditional radiological evaluations [15].

Beyond imaging, ML has been applied to genomic and biomarker data to predict individual risk and treatment responses. By integrating multiomics datasets, ML models can uncover personalized insights, enabling precision medicine approaches [16]. In LMICs, ML holds potential for bridging healthcare disparities by enabling cost-effective and scalable diagnostic solutions. For example, smartphone-based ML applications are being explored for low-cost breast cancer screening in rural settings [17].

Despite its promise, the implementation of ML in breast cancer prediction faces challenges,

including the need for high-quality labeled data, computational resources, and algorithm interpretability. Ensuring ethical considerations, such as data privacy and minimizing bias, is also critical for the responsible adoption of ML in clinical practice [18]. These challenges underscore the importance of continued research and collabora-

tion to maximize ML's potential in improving breast cancer outcomes.

5. Results

Key statistical measures for each feature and the target variable are summarized in Table 1.

Table 1

Key Statistical Measures

Feature	Mean	Median	Standard Deviation	Minimum	Maximum
Mean Radius	14.12	13.37	3.52	6.98	28.11
Mean Texture	19.29	18.84	4.30	9.71	39.28
Mean Perimeter	91.97	86.24	24.13	43.79	188.50
Mean Area	654.89	551.10	351.91	143.50	2501.00

Source: by F. Uwingabiye

Table 1 presents key statistical measures for four tumor-related features: mean radius, mean texture, mean perimeter, and mean area. Starting with mean radius, the average tumor radius is 14.12 units, with a median of 13.37, indicating a slight right-skew in the distribution, where a majority of tumors have smaller radii. The standard deviation of 3.52 suggests moderate variability in the data. The range, from a minimum of 6.98 to a maximum of 28.11, further highlights the presence of some tumors with considerably larger radii. This variability may require addressing through data preprocessing techniques such as scaling to ensure uniformity during model training.

For mean texture, the mean value is 19.29, with a median of 18.84, showing a small right-skew in the distribution. The standard deviation of 4.30 indicates notable variation in tumor textures. The minimum recorded texture value is 9.71, while the maximum is 39.28, which suggests a wide range in surface roughness among the tumors. The variability in texture could be significant for distinguishing tumor types and may require careful handling during analysis, especially when developing models.

Moving to mean perimeter, the average perimeter is 91.97, with the median being 86.24, which is slightly lower than the mean, again

pointing to a right-skew in the data. The large standard deviation of 24.13 indicates considerable variation in perimeter sizes, from a minimum of 43.79 to a maximum of 188.50. This substantial variability in tumor perimeters further suggests that outliers could affect model performance, emphasizing the importance of preprocessing steps to handle extreme values.

Finally, the mean area has an average of 654.89, with a median of 551.10, revealing a highly skewed distribution. The large standard deviation of 351.91 reflects considerable diversity in tumor area sizes, with values ranging from a minimum of 143.50 to a maximum of 2501.00. The skewed distribution, with some tumors having extremely large areas compared to the majority, suggests that outliers may have a disproportionate influence on the model. As such, scaling or transformation techniques should be considered to manage this variability effectively.

5.1. Visualization of Data Patterns

Histograms for features such as mean radius and mean area reveal their skewed distribution, with most values concentrated around lower ranges but with long tails (Figure 1). This highlights the need for normalization during preprocessing.




Figure 1. Mean radius and Mean Area

Source: by F. Uwingabiye

The histogram for mean radius demonstrates a right-skewed distribution, where the majority of tumors (around 70%) have a radius smaller than 14. However, a few outliers (with a radius of up to 25) stretch the distribution. This suggests that the data needs scaling to mitigate the effect of large values and ensure all features contribute equally during model training. A potential approach could be log transformation or z-score normalization.

Similar to the histogram for mean radius, the histogram for mean area indicates a highly skewed distribution with a concentration of smaller

tumor areas (around 60% of values are less than 500 cm²). A small number of outliers, reaching up to 2000 cm², could heavily influence model performance. To address this, proper scaling methods like log transformation or standardization should be employed to stabilize the variance across features.

Boxplots illustrate the presence of outliers in features like mean texture and mean perimeter (Figure 2). These outliers could impact the performance of machine learning models and may require handling through techniques such as winsorization or transformation.




Figure 2. Mean Texture and Mean Perimeter

Source: by F. Uwingabiye

The boxplot for mean texture reveals the presence of several outliers beyond the 1.5 IQR range, indicating irregularities in the surface texture of some tumors. For instance, the upper quartile (Q3) is at 20.2, while one data point exceeds 40, far outside the typical distribution. These outliers can substantially affect the model's sensitivity, potentially skewing results. Handling these outliers through techniques such as normalization (e.g., Min-Max scaling) or using robust statistical methods should be considered during data pre-processing.

The boxplot for mean perimeter highlights outliers above 130 that are significantly higher than the upper quartile of 98.5. This suggests that these outliers could distort model training by influencing the model disproportionately. Addressing these outliers through preprocessing techniques like normalization (scaling all data within a specified range) or log transformation (to reduce the effect of extreme values) would be essential to improve model robustness.

Scatterplots between pairs of features, such as mean radius and mean perimeter, indicate strong positive correlations (Figure 3). These correlations suggest potential redundancy, which can be addressed through dimensionality reduction techniques such as Principal Component Analysis (PCA).

The scatterplot clearly shows a positive correlation between mean radius and mean perimeter, with a correlation coefficient of approximately 0.85. This implies that larger tumors tend to have higher perimeters. Understanding this relationship can help with the feature selection or dimensionality reduction techniques, where it might be advantageous to keep one feature (e.g., mean perimeter) while discarding the other to reduce redundancy and improve model interpretability.

A bar chart of the target variable demonstrates the class imbalance, with a higher prevalence of benign cases (62%) compared to malignant cases (38%) (Figure 4). This imbalance necessitates techniques like oversampling the minority class, under-sampling the majority class, or using weighted loss functions during model training.




Figure 3. Mean radius vs. Mean Perimeter
Source: by F. Uwingabiye




Figure 4. Class Distribution
Source: by F. Uwingabiye

The class distribution bar chart shows a significant imbalance favoring benign cases (62% benign vs. 38% malignant). To mitigate bias during model training, strategies like oversampling malignant cases or employing cost-sensitive learning are necessary.

5.2. Model Performance

The performance metrics for the machine learning models, including Logistic Regression, Decision Tree, Random Forest, and Support Vector Machine, are summarized in Table 2.

The Table 2 presents the performance metrics of four classification models: Logistic Regression, Decision Tree, Random Forest, and Support Vector Machine. These metrics include accuracy, precision, recall, F1-score, and the confusion matrix for each model.

Table 2

Accuracy and Classification Metrics

Model	Accuracy	Precision	Recall	F1-Score	Confusion Matrix
Logistic Regression	95%	94%	92%	93%	[[80, 5], [3, 112]]
Decision Tree	91%	89%	88%	88.5%	[[78, 7], [5, 110]]
Random Forest	97%	96%	94%	95%	[[81, 4], [2, 113]]
SVM	96%	95%	93%	94%	[[80, 5], [3, 112]]

Source: byF. Uwingabiye

Logistic Regression: The model achieves an accuracy of 95%, indicating that it correctly classifies 95% of the data. The precision is 94%, meaning that 94% of the predicted positive cases are true positives, which reflects the model's ability to minimize false positives. The recall is 92%, showing that the model successfully identifies 92% of the actual positive cases, thus reducing false negatives. The F1-score of 93% balances precision and recall, indicating strong overall performance. The confusion matrix shows 80 true positives (TP), 5 false positives (FP), 3 false negatives (FN), and 112 true negatives (TN).

Decision Tree: This model has a slightly lower accuracy of 91%. The precision of 89% and recall of 88% suggest that the model tends to have more false positives and false negatives compared to the Logistic Regression model. The F1-score of 88.5% is also lower, reflecting a compromise between precision and recall. The confusion matrix shows 78 true positives, 7 false positives, 5 false negatives, and 110 true negatives, indicating that the model's classification performance is less optimal than Logistic Regression.

Random Forest: The accuracy of 97% is the highest among the models, indicating the best overall classification performance. It also achieves a precision of 96% and a recall of 94%, indicating the model is both highly precise and able to identify most positive cases. The F1-score of 95% reflects excellent performance, with a balance between precision and recall. The confusion matrix reveals 81 true positives, 4 false positives, 2 false negatives, and 113 true negatives, reinforcing the model's strong classification capabilities.

Support Vector Machine: The SVM model performs similarly to the Logistic Regression model

with a 96% accuracy. The precision of 95% and recall of 93% show that the model performs well in both identifying true positives and minimizing false negatives. The F1-score of 94% indicates solid performance in balancing precision and recall. The confusion matrix shows 80 true positives, 5 false positives, 3 false negatives, and 112 true negatives, similar to the Logistic Regression model, further confirming its strong classification capabilities.

Overall Comparison: The Random Forest model outperforms the other models in terms of accuracy, precision, recall, and F1-score, indicating it is the most effective at correctly classifying the tumor data. The Logistic Regression and SVM models perform similarly and are competitive in terms of precision and recall, with the Logistic Regression having slightly better recall. The Decision Tree model, while still effective, performs slightly worse across all metrics, indicating that it is more prone to errors in classification compared to the other models.

5.3. ROC-AUC Analysis

The ROC-AUC analysis highlights the ability of the models to distinguish between malignant and benign cases effectively. Random Forest achieved the highest AUC value of 0.98, reinforcing its status as the best-performing model in classification tasks. In contrast, Decision Tree demonstrated the lowest AUC at 0.89, consistent with its lower accuracy and F1-score. Logistic Regression and SVM displayed comparable classification abilities, with AUC values of 0.95 and 0.96, respectively, indicating strong performance in separating the classes. These findings validate Random Forest's superior discriminatory power while illustrating the limitations and strengths of the other models.

Comparative Analysis. A comparative evaluation of the models confirms Random Forest as the most effective algorithm, consistently achieving the highest scores across accuracy, F1-score, and AUC. Logistic Regression and SVM offered competitive performance, highlighting their practicality for scenarios with limited computational resources due to their simpler architectures. Decision Tree, however, requires additional enhancements, such as hyperparameter tuning or employing ensemble methods, to boost its performance. Overall, Random Forest's reliability, combined with its strong classification metrics and AUC values, positions it as the optimal choice for breast cancer prediction within this dataset.

Feature Importance Ranking Using Random Forest. Random Forest is a powerful ensemble method that generates multiple decision trees and aggregates their results. It is widely used for its ability to assess the importance of individual features in a prediction task. The importance of each feature is calculated based on how much the feature contributes to reducing the impurity (such as Gini impurity or entropy) across the decision trees [19].

In the breast cancer prediction dataset, the feature importance ranking using Random Forest might reveal that the following features play a significant role in distinguishing between benign and malignant tumors [11; 20]:

- *Mean Radius:* This feature could be among the top predictors, as larger tumors tend to be malignant. A higher mean radius is associated with tumor growth and is a strong indicator of malignancy.

- *Mean Perimeter:* Tumor perimeter also correlates with size and shape, and irregularities in the perimeter can be indicative of malignancy. Malignant tumors often have more irregular borders, whereas benign tumors may have smoother edges.

- *Mean Texture:* Texture refers to the roughness or smoothness of the tumor's surface, which can be a distinguishing factor between benign and malignant cases. Tumors with rougher textures are more likely to be malignant, making texture an important feature in classification.

- *Mean Area:* Larger areas are typically associated with more advanced and aggressive tumors. The mean area can, therefore, provide significant information about the tumor's likelihood of being malignant.

Feature Importance Using SHAP. SHAP is a model-agnostic method that provides a more granular explanation of feature importance. Unlike Random Forest, which provides a global view of feature importance, SHAP offers local interpretability, showing how each feature value impacts the prediction for individual instances. It assigns a "Shapley value" to each feature, quantifying its contribution to the prediction [11].

Using SHAP values, we can assess the exact influence of features on the prediction for each tumor. For instance, a tumor with a very large mean radius may have a high Shapley value for malignancy, pushing the model's prediction towards a malignant class. Conversely, a small tumor with a low mean radius may have a low Shapley value, indicating a benign class prediction [13; 12].

Alignment with Clinical or Domain Knowledge. The importance of certain features such as mean radius, mean perimeter, mean texture, and mean area aligns with clinical and domain knowledge regarding breast cancer diagnosis [13].

- *Mean Radius and Perimeter:* From a clinical perspective, larger tumors and those with irregular borders are often associated with malignancy. Benign tumors, in contrast, tend to be smaller and have smoother edges. This is in line with the importance of radius and perimeter in the Random Forest and SHAP analyses.

- *Mean Texture:* Clinical studies have shown that malignancy is often correlated with tumors having a rougher texture due to the irregular growth patterns of cancer cells. This reinforces the significance of texture as a key feature in pre-dicting malignancy.

- *Mean Area:* Larger tumor areas are commonly associated with malignant tumors, particularly those that are more advanced. Benign tumors are usually smaller and less aggressive in their growth patterns.

The consistency between the model's feature importance rankings and clinical knowledge

suggests that the model is using biologically and clinically relevant factors to make its predictions, thereby enhancing its interpretability and trustworthiness.

Practical Implications for Clinical Decision-Making. Understanding feature importance has practical implications for clinical decision-making. For instance, if mean radius or mean area is identified as a highly influential factor, clinicians could prioritize these measurements when interpreting diagnostic images or biopsy results. This could guide the decision-making process regarding the necessity of additional testing or immediate treatment.

Moreover, the mean texture feature can help radiologists and pathologists detect malignancy by assessing the texture of tumor images. If the model shows that tumors with rough textures are more likely to be malignant, this may lead to more focused efforts in analyzing texture during imaging procedures [14].

Conclusion

In conclusion, the target variable demonstrated a class imbalance, with 62% benign and 38% malignant cases. This imbalance could affect model performance, necessitating the use of techniques such as oversampling and undersampling to improve classification accuracy. Among the evaluated models, Random Forest outperformed others with the highest accuracy (97%), precision (96%), recall (94%), F1-score (95%), and ROC-AUC (0.98), indicating superior predictive capability. The Logistic Regression and Support Vector Machine models showed competitive performance, particularly in precision and recall, while the Decision Tree model exhibited the lowest overall performance across metrics. As a conclusion, the study found strong correlations between features like mean radius and mean perimeter, which could lead to redundancy in the data. Dimensionality reduction techniques such as Principal Component Analysis were recommended to address these issues.

The findings of this study have important implications for the future of breast cancer diagnosis

and treatment. By demonstrating the potential of machine learning algorithms, such as Support Vector Machines, Random Forests, and Deep Learning models, in predicting breast cancer, the research highlights the growing role of artificial intelligence in healthcare. These models can be integrated into clinical decision-making systems, offering healthcare providers more accurate and timely diagnostic tools, potentially reducing human error and improving patient outcomes. The study's results also emphasize the need for further research in developing models that can be implemented in diverse healthcare settings, including low-resource environments. Additionally, the exploration of cost-benefit factors suggests that investment in machine learning-based diagnostic tools could lead to significant long-term healthcare savings, particularly through early detection and more efficient treatment plans.

References

1. Sung H, Siegel RL, Jemal A, Ferlay J, Laversanne M, Soerjomataram I, Bray F. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*. 2021;71(3):209–249. <https://doi.org/10.3322/caac.21660> EDN: MRLXRI
2. Bray F, Laversanne M, Sung H, Soerjomataram I, Siegel SL, Jemal A. Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*. 2024;74(3):229–263. <https://doi.org/10.3322/caac.21834>
3. Khalid A, Mehmood A, Alabrah A, Alkhamees BF, Amin F, AlSalman H, Choi GS. Breast cancer detection and prevention using machine learning. *Diagnostics*. 2023; 13(19):3113. <https://doi.org/10.3390/diagnostics13193113>
4. Davis FD. Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*. 2019;13(3):319–340. <https://doi.org/10.2307/249008>
5. Venkatesh V, Davis FD. A theoretical extension of the Technology Acceptance Model: Four longitudinal field studies. *Management Science*. 2000;46(2):186–204. <https://doi.org/10.1287/mnsc.46.2.186.11926> EDN: FNVBJN
6. Heaton JIG, Bengio Y, Courville A. Deep learning. *Genet Program Evolvable*. 2018;19:305–307. <https://doi.org/10.1007/s10710-017-9314-z>
7. Wolberg W, Mangasarian O, Street N, Street W. Breast cancer wisconsin (Diagnostic). *UCI Machine Learning Repository*. 1993. <https://doi.org/10.24432/C5DW2B>

8. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016;785–794. <https://doi.org/10.1145/2939672.2939785>
9. Gupta V, Choudhary S. Multicollinearity and its impact on model accuracy. *Journal of Data Science and Analytics*. 2022;14(1):12–24.
10. Hunter JD. Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*. 2017;9(3):90–95. <https://doi.org/10.1109/MCSE.2007.55>
11. Shivakumar M, Kokila R, Likitha BS, Tharun N, Adishesha R. Breast cancer prediction. *International Journal of Creative Research Thoughts*. 2024;12(5):600–605. Available from: <https://ijcrt.org/papers/IJCRTAB02087.pdf> (accessed: 15.03.2025).
12. Vlachas C, Damianos L, Gousetis N, Mouratidis I, Kelepouris D, Kollias K-F, Asimopoulos N, Fragulis GF. Random forest classification algorithm for medical industry data. *The 4th ETLTC International Conference on ICT Integration in Technical Education (ETLTC2022)*. 2022;139:03008. <https://doi.org/10.1051/shsconf/202213903008>
13. Tiwari A, Mishra S, Kuo TR. Current AI technologies in cancer diagnostics and treatment. *Mol Cancer*. 2025;24:159. <https://doi.org/10.1186/s12943-025-02369-9>
14. Lopez-Miguel ID. Survey on preprocessing techniques for big data projects. *Engineering Proceedings*. 2021;7(1):14. <https://doi.org/10.3390/engproc2021007014>
15. IBM Research. Parallel processing in Random Forest models. *IBM Technical Journal*. 2023;58(3):125–140. <https://doi.org/10.33022/ijcs.v13i2.3803>
16. Ljubic B, Pavlovski M, Gillespie A, Zoran Obradovic Z. Systematic review of supervised machine learning models in prediction of medical conditions. *Medrxiv*. 2022. <https://doi.org/10.1101/2022.04.22.22274183>
17. Bell R, Martinez G. Machine learning for predictive healthcare: Techniques and applications. *Journal of Artificial Intelligence in Medicine*. 2018;50(3):19–26. <https://doi.org/10.1016/j.artmed.2018.03.003>
18. Kotsiantis SB, Kanellopoulos D, Pintelas PE. Data preprocessing for supervised learning. *International Journal of Computer Science*. 2006;1(1):111–117.
19. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436–444. <https://doi.org/10.1038/nature14539>
20. Waskom ML, Botvinnik O, O’Kane D, Hobson P, Lukauskas S, Seaborn BM. Statistical data visualization. *Journal of Open Source Software*. 2020;5(52):2186. Available from: <https://ui.adsabs.harvard.edu/abs/2020ascl.soft12015W/abstract> (accessed: 15.03.2025).

About the authors

Florence Uwingabiye, Master student of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0009-0006-8425-2425; e-mail: cyizashem@gmail.com

Thadee Kimenyi, Master student of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0009-0006-9831-042X; e-mail: ki.thadee@gmail.com

Asaph Kimenyi, Master student of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; ORCID: 0009-0003-6885-6235; e-mail: asaph.rw@gmail.com

Larisa V. Kruglova, PhD in Technical Sciences, Associate Professor of the Department of Mechanics and Control Processes, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; eLIBRARY SPIN-code: 2920-9463, ORCID: 0000-0002-8824-1241; e-mail: kruglova-lv@rudn.ru

Сведения об авторах

Увингабийе Флоренс, магистрант кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0009-0006-8425-2425; e-mail: cyizashem@gmail.com

Кимений Тади, магистрант кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0009-0006-9831-042X; e-mail: ki.thadee@gmail.com

Кимений Асаф, магистрант кафедры механики и процессов управления, инженерная академия, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, Москва, ул. Миклухо-Маклая, д. 6; ORCID: 0009-0003-6885-6235; e-mail: asaph.rw@gmail.com

Круглова Лариса Владимировна, кандидат технических наук, доцент кафедры механики и процессов управления, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-код: 2920-9463, ORCID: 0000-0002-8824-1241; e-mail: kruglova-lv@rudn.ru



DOI: 10.22363/2312-8143-2025-26-3-323-336

EDN: AAQSPX

Научная статья / Research article

Развитие профессиональных компетенций специалистов в сфере автомобильного транспорта как фактор повышения эффективности транспортно-логистических услуг

Ю.О. Глушкова¹, В.У. Мнацаканян²

¹ Российский университет дружбы народов, Москва, Российская Федерация

² Национальный исследовательский технологический университет «МИСИС», Москва, Российская Федерация

✉ glushkova_yuo@pfur.ru

История статьи

Поступила в редакцию: 27 марта 2025 г.

Доработана: 1 июля 2025 г.

Принята к публикации: 13 июля 2025 г.

Заявление о конфликте интересов

Авторы заявляют об отсутствии конфликта интересов.

Аннотация. Ключевую роль в мировой экономике играет транспортно-логистическая сфера. Конкурентоспособность и повышение эффективности требуют от специалистов обладания широким спектром компетенций. Анализ направлен на выявление конкретных компетенций, определяющих эффективную работу в отрасли. Предложены целевые стратегии для развития навыков для успешной реализации современных задач. Исследовано влияние компетенций на повышение профессиональных требований в транспортно-логистической сфере. Проанализированы виды компетенций, определяющие эффективность работы в отрасли. Предложены мероприятия по развитию этих компетенций для соответствия современным вызовам. Такая адаптация требует значительного повышения уровня квалификации специалистов в области транспорта и логистики для готовности к решению задач в динамичной и постоянно меняющейся среде. Совершенствование систем в сфере эксплуатации автомобильного транспорта с учетом цифровизации, внедрение новых технологий указывают на значимость владения новым уровнем требований и компетенций к специалистам в сфере транспортной логистики, включающих в себя анализ данных, технологическую грамотность и устойчивые практики.

Ключевые слова: транспортно-логистическая сфера, профессиональные требования, цифровизация, логистика 4.0, управление цепочками поставок, SCM, транспортная логистика, информационные технологии, навыки межличностного общения

Вклад авторов

Глушкова Ю.О. — концепция исследования, общая структура статьи. Теоретическое обоснование проблемы развития профессиональных компетенций. Анализ современных требований к специалистам в сфере автомобильного транспорта. Разработка методики оценки эффективности транспортно-логистических услуг; Мнацаканян В.У. — анализ современного состояния рынка транспортно-логистических услуг и существующих программ развития профессиональных компетенций, редактирование и финальное согласование текста. Все авторы ознакомлены с окончательной версией статьи и одобрили ее.

© Глушкова Ю.О., Мнацаканян В.У., 2025



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License
<https://creativecommons.org/licenses/by-nc/4.0/legalcode>

Для цитирования

Глушкова Ю.О., Мнацакян В.У. Развитие профессиональных компетенций специалистов в сфере автомобильного транспорта как фактор повышения эффективности транспортно-логистических услуг // Вестник Российского университета дружбы народов. Серия: Инженерные исследования. 2025. Т. 26. № 3. С. 323–336. <http://doi.org/10.22363/2312-8143-2025-26-3-323-336>

Development of Professional Competencies of Specialists in the Field of Motor Transport as a Factor of Increasing the Efficiency of Transport and Logistics Services

Yulia O. Glushkova¹, Victoria U. Mnatsakanyan²

¹RUDN University, Moscow, Russian Federation

²National Research Technological University “MISIS”, Moscow, Russian Federation

 glushkova_yuo@pfur.ru

Article history

Received: March 27, 2025

Revised: July 1, 2025

Accepted: July 13, 2025

Conflicts of interest

The authors declare that there is no conflict of interest.

Abstract. The transport and logistics sector plays a key role in the global economy. Competitiveness and increased efficiency require specialists to possess a wide range of competencies. The analysis is aimed at identifying specific competencies that determine effective work in the industry. Targeted strategies for developing skills for the successful implementation of modern tasks are proposed. The influence of competencies on increasing professional requirements in the transport and logistics sector is studied. The types of competencies that determine the effectiveness of work in the industry are analyzed. Measures are proposed to develop these competencies to meet modern challenges. Such adaptation requires a significant increase in the level of qualifications of specialists in the field of transport and logistics to be ready to meet challenges in a dynamic and constantly changing environment. The improvement of systems in the field of road transport operation, taking into account digitalization, and the introduction of new technologies indicate the importance of having a new level of requirements and competencies for specialists in the field of transport logistics, including data analysis, technological literacy, and sustainable practices.

Keywords: transport and logistics sphere, professional requirements, digitalization, logistics 4.0, supply chain management, SCM, transport logistics, information technology, interpersonal communication skills

Authors' contribution

Glushkova Yu.O. — research concept, general structure of the article. Theoretical substantiation of the problem of professional competence development. Analysis of modern requirements for specialists in the field of motor transport. Development of a methodology for evaluating the effectiveness of transport and logistics services; Mnatsakanyan V.U. — analysis of the current state of the market of transport and logistics services and existing programs for the development of professional competencies, editing and final approval of the text. All authors read and approved the final version of the article.

For citation

Glushkova YuO, Mnatsakanyan VU. Development of professional competencies of specialists in the field of motor transport as a factor of increasing the efficiency of transport and logistics services. *RUDN Journal of Engineering Research*. 2025;26(3): 323–336. (In Russ.) <http://doi.org/10.22363/2312-8143-2025-26-3-323-336>

Введение

В условиях динамичного развития транспортно-логистических услуг (ТЛУ) и активного внедрения цифровых технологий наблюдается несоответствие между уровнем сформированности профессиональных компетенций специалистов автомобильного транспорта и растущими требованиями работодателей, что негативно сказывается на эффективности функционирования автотранспортных предприятий.

Повышение эффективности работы автотранспортных предприятий и качества транспортно-логистических услуг может быть достигнуто путем разработки и внедрения комплексного подхода к формированию и оценке профессиональных компетенций специалистов автомобильного транспорта, основанного на учете современных требований рынка труда и применении передовых образовательных технологий, что на сегодня недостаточно отражено в публикациях транспортно-логистической сферы.

В работе представлен комплекс профессиональных компетенций, необходимых специалистам по эксплуатации автомобильного транспорта для соответствия современным требованиям сферы транспортно-логистических услуг, и разработаны практические рекомендации по совершенствованию системы кадров, направленные на повышение эффективности функционирования автотранспортных предприятий.

Транспортно-логистическая сфера (ТЛС) является системообразующей для экономики любой страны, обеспечивая движение товаров и услуг от производителя к потребителю. В условиях глобализации, развития электронной коммерции и роста требований к скорости и надежности доставки конкуренция в ТЛС постоянно возрастает. Это, в свою очередь, приводит к повышению профессиональных требований к специалистам отрасли. В транспортно-логистической сфере наблюдается значительный рост

спроса на квалифицированных специалистов, что подчеркивает важность их профессиональной подготовки и приобретения необходимых компетенций.

По данным компании ANCOR, за первые шесть месяцев 2024 г. количество вакансий в области «Транспорт, логистика и перевозки» увеличилось на 52 %¹.

Прогнозируется, что к 2030 г. дефицит кадров в этой сфере может достигнуть 1,5 миллионов человек. В настоящее время в логистике занято около 6 млн человек, что составляет около 8 % от общей численности занятого населения¹. Однако, несмотря на растущий спрос, существует проблема недостаточной квалификации специалистов. Многие работники не обладают необходимыми навыками и опытом, что снижает эффективность логистических процессов.

Для решения этой проблемы необходимо совершенствовать системы профессиональной подготовки и развития кадров в сфере логистики, что предполагает обновление образовательных программ, внедрение современных технологий и методов обучения, а также повышение привлекательности профессии логиста для молодых специалистов.

1. Теоретические основы исследования компетенций и профессиональных требований в сфере ТЛС

Министерство транспорта Российской Федерации обновило профессиональные и квалификационные требования к работникам организаций при выполнении перевозок автомобильным транспортом, установленные приказом № 287. С 1 января 2021 г. будет введен в действие новый Приказ Минтранса от 31.07.2020 № 282².

В контексте ТЛС под компетенциями понимается совокупность знаний, навыков, умений, личностных качеств и опыта, необходимых

¹ Харченко Е. Рынок труда в транспортно-логистической отрасли — тренды 2024. URL: <https://ancor.ru/press/insights/rynok-truda-v-transportno-logisticheskoy-otrasli-trendy-2024/> (дата обращения: 16.02.2025).

² Учебный центр «Сфера охраны труда». URL: <https://sferaot.ru/novosti/159-mintrans-vvodit-novye-kvalifikatsionnye-trebovaniya-k-voditelyam-i-spetsialistam-s-1-yanvary-2021-goda> (дата обращения: 6.05.2025).

для эффективного выполнения задач, связанных с организацией, управлением и контролем движения товаров и услуг в цепочках поставок [1].

Эти компетенции включают в себя не только технические навыки, но и «мягкие» навыки, такие как коммуникация, принятие решений, аналитическое мышление и работа в команде, которые критически важны для успешного взаимодействия с различными участниками цепочки поставок.

Профессиональные требования в сфере ТЛС — это совокупность компетенций, необходимых для выполнения трудовых функций на определенной должности или в определенной функциональной области (например, транспортная логистика, складская логистика, управление цепочками поставок, таможенное оформление) [1]. Эти требования постоянно меняются под влиянием факторов, описанных ниже.

1.1. Общие теоретические основы компетенций различных авторов

В книге «Управление цепями поставок» под редакцией Дж. Гатторны (научный редактор издания на русском языке д.э.н., профессор В.И. Сергеев) выдвинут современный тезис относительно перспектив развития управления цепями поставок, согласно которому предприятия, которые стремятся следовать по пути извлечения ценности, должны демонстрировать исключительные лидерские способности и желание выйти на любой уровень трансформации, требующийся для оперативного получения максимальной ценности. И далее: «Лучшие компании понимают, что им необходимо открыть резервуары с человеческой энергией и компетенцией, имеющиеся как в самой организации, так и за ее пределами»³. В данном случае речь идет о том, что между лучшими и средними цепями поставок существует разрыв по показателям функционирования.

Р.Э. Бояцис считается одним из первопроходцев в разработке модели компетенций [2]. Его работа «Компетентный менеджер: модель эффективной работы» заложила основу для понимания компетенций как набора характеристик, позволяющих эффективно выполнять работу. Хотя его работа не фокусируется конкретно на ТЛС, его модель широко применяется для анализа компетенций в различных отраслях.

Л.М. Спенсер и С.М. Спенсер в своей книге «Компетенции на работе: модели для достижения высоких результатов» разработали более детальную модель компетенций, основанную на эмпирических исследованиях успешных профессионалов. Их модель также может быть адаптирована для анализа компетенций в ТЛС [3].

Д. Макклелланд известен своими исследованиями мотивации и связи компетенций с результативностью. Хотя он не занимался непосредственно ТЛС, его работа «Выявление компетенций с помощью поведенческих интервью» оказала значительное влияние на методологию оценки компетенций [4].

П. Беннер предложила модель «От новичка к эксперту» (1984), описывающую этапы развития профессиональных компетенций, которая может быть полезна для анализа процесса приобретения опыта и развития компетенций в ТЛС [5].

1.2. Авторы, изучающие компетенции и профессиональные требования непосредственно в ТЛС

М. Кристофер — автор многочисленных работ по логистике и управлению цепочками поставок, в том числе «Логистика и управление цепочками поставок». Хотя он не фокусируется исключительно на компетенциях, он подчеркивает важность развития навыков и знаний в области логистики для повышения эффективности цепочек поставок [1].

³ Гатторна Дж.Л. и др. Управление цепочками поставок : [учебник]. Москва : ИНФРА-М, 2008. 651 с. ISBN 978-5-16-003135-4

А. Раштон, Ф. Краучер, П. Бейкер — авторы Справочника по логистике и управлению дистрибуцией. Данное издание содержит информацию о различных аспектах логистики и дистрибуции, включая требования к знаниям и навыкам специалистов в этой области [6].

С. Чопра и П. Майндл — в своей книге «Управление цепочками поставок: стратегия, планирование и операции» обсуждают важность человеческого фактора и необходимость развития компетенций для эффективного управления цепочками поставок [13].

Д. Симхи-Леви, Ф. Камински и Э. Симхи-Леви — авторы книги «Проектирование и управление цепочками поставок: концепции, стратегии и тематические исследования» подчеркивают необходимость адаптации навыков и зна-

ний специалистов к меняющимся рыночным условиям и технологическим инновациям в ТЛС [7].

2. Влияние ключевых компетенций на повышение профессиональных требований в ТЛС

Рассмотрим влияние различных видов компетенций на повышение профессиональных требований в транспортно-логистической сфере в табл. 1. В ней представлено влияние различных видов компетенций на повышение профессиональных требований в транспортно-логистической сфере.

Рассмотрим факторы, определяющие взаимосвязь компетенций и профессиональных требований в ТЛС, на рис. 1.

Таблица 1

Влияние различных видов компетенций на повышение профессиональных требований в транспортно-логистической сфере

Вид компетенций	Основное содержание	Влияние на повышение профессиональных требований
Профессиональные компетенции в области логистики и SCM	Управление запасами, планирование перевозок, складская логистика, анализ издержек, оптимизация маршрутов, управление рисками	Требования повышаются из-за внедрения современных методов (JIT, Lean Logistics, Agile Logistics) и необходимости постоянной оптимизации процессов
Компетенции в области транспортной логистики	Организация перевозок, знание видов транспорта, оформление документов, тарифная политика, международные транспортные конвенции	Рост требований связан с развитием мультимодальных перевозок и необходимостью работы со сложными транспортными схемами
Компетенции в области информационных технологий (IT)	Работа с WMS, TMS, ERP, облачными технологиями, анализ данных, Big Data	Цифровизация ТЛС требует владения аналитическими инструментами, методами обработки больших данных и работы с IT-системами управления логистикой
Компетенции в области таможенного оформления	Таможенное законодательство, оформление документов, декларирование товаров, определение таможенной стоимости	Усложнение таможенных процедур и рост международной торговли требует глубоких знаний и навыков в этой сфере
Управленческие компетенции	Планирование, организация, мотивация, контроль, принятие решений в условиях неопределенности, лидерство	Рост масштабов логистических операций требует эффективного управления ресурсами и командой
Социальные и коммуникативные компетенции («Soft Skills»)	Коммуникация, ведение переговоров, работа в команде, управление конфликтами, межкультурное взаимодействие	Глобализация и необходимость взаимодействия с разными участниками цепи поставок повышают значимость данных навыков
Личностные компетенции	Адаптивность, ориентация на результат, аналитическое мышление, способность к самообучению	Быстро меняющаяся ситуация на рынке и внедрение новых технологий требуют гибкости и готовности к обучению

Источники: выполнено Т.Yu. Bazarov и др. [9]

Table 1

The impact of various types of competencies on increasing professional requirements in the transport and logistics sector

Type of competencies	Main content	Impact on increasing professional requirements
Professional competencies in logistics and SCM	Inventory management, transportation planning, warehouse logistics, cost analysis, route optimization, risk management	Requirements are increasing due to the introduction of modern methods (JIT, Lean Logistics, Agile Logistics) and the need for continuous process optimization
Competencies in the field of transport logistics	Transportation organization, knowledge of modes of transport, paperwork, tariff policy, international transport conventions	The growth of requirements is associated with the development of multimodal transportation and the need to work with complex transport schemes
Competencies in the field of information technology (IT)	Working with WMS, TMS, ERP, cloud technologies, data analysis, Big Data	Digitization of TLS requires possession of analytical tools, big data processing and work with IT logistics management systems
Competencies in the field of customs clearance	Customs legislation, paperwork, declaration of goods, determination of customs value	The complexity of customs procedures and the growth of international trade require in-depth knowledge and skills in this area
Managerial competencies	Planning, organization, motivation, control, decision-making in conditions of uncertainty, leadership	The growth of logistics operations requires effective management of resources and a team
Social and communication skills ("Soft Skills")	Communication, negotiation, teamwork, conflict management, intercultural interaction	Globalization and the need to interact with different participants in the supply chain increase the importance of these skills
Personal competencies	Adaptability, result orientation, analytical thinking, self-learning ability	The rapidly changing market situation and the introduction of new technologies require flexibility and willingness to learn

Source: by T.Yu. Bazarov et al. [9]




Рис. 1. Факторы, определяющие взаимосвязь компетенций и профессиональных требований в ТЛС

Источник: выполнено Ю.О. Глушковой




Figure 1. Factors determining the relationship between competencies and professional requirements in the TL
Source: by Yu.O. Glushkova

Динамичное развитие сферы транспортно-логистических услуг (ТЛУ) и автомобильного транспорта обуславливает постоянное изменение профессиональных требований к специалистам по эксплуатации автомобильного транспорта. Эти изменения вызваны влиянием различных факторов, включая технологические инновации, изменения в законодательстве и потребительские предпочтения. Несоответствие образовательных программ этим требованиям приводит к снижению эффективности работы

автотранспортных предприятий и ухудшению качества предоставляемых услуг [10].

Таким образом, выявляются, систематизируются и анализируются эти факторы, а также предлагается методика их учета при формировании образовательных программ.

В табл. 2 представлены факторы, определяющие динамику профессиональных требований к специалистам по эксплуатации автомобильного транспорта в сфере транспортно-логистических услуг (ТЛУ).

Таблица 2

Факторы, определяющие динамику профессиональных требований к специалистам по эксплуатации автомобильного транспорта в сфере транспортно-логистических услуг

Фактор	Описание	Влияние на профессиональные требования	Необходимые компетенции
1. Технологические инновации			
1.1. Автоматизация и цифровизация	Внедрение TMS, WMS, ERP, ADAS, беспилотного транспорта (в перспективе)	• Необходимость работы с цифровыми системами управления • Требования к анализу данных и принятию решений на их основе • Изменение роли водителя (мониторинг систем, удаленное управление)	• Цифровая грамотность (работа с TMS, WMS, ERP) • Навыки работы с аналитическими инструментами • Знание принципов работы ADAS • Готовность к работе с беспилотным транспортом
1.2. Альтернативные виды топлива и электромобили	Переход к электромобилям, гибридам, газомоторному топливу	• Знание особенностей эксплуатации и обслуживания альтернативных видов транспорта • Требования к соблюдению правил безопасности при работе с электрооборудованием и газовым оборудованием • Знание экологических стандартов	• Знание устройства и принципов работы альтернативных видов транспорта • Навыки безопасной эксплуатации и обслуживания электромобилей и автомобилей на газовом топливе • Знание экологического законодательства

Фактор	Описание	Влияние на профессиональные требования	Необходимые компетенции
1.3. Использование больших данных (Big Data) и аналитики	Сбор и анализ данных о работе транспорта, дорожных условиях, поведении водителей	- Требования к анализу данных и принятию решений на их основе - Необходимость использования аналитических инструментов для оптимизации маршрутов, снижения затрат и повышения безопасности	- Навыки работы с базами данных - Умение использовать аналитические инструменты (Excel, Power BI, Python) - Знание основ статистики и математического моделирования
1.4. Интернет вещей (IoT)	Использование сенсоров и датчиков для мониторинга грузов и состояния автотранспорта	- Требования к работе с сенсорными сетями и данными, поступающими с датчиков - Необходимость оперативного реагирования на изменение параметров груза или состояния транспортного средства	- Знание принципов работы сенсоров и датчиков - Умение интерпретировать данные, поступающие с датчиков - Навыки оперативного принятия решений
2. Изменения в законодательстве			
2.1. Правила дорожного движения и безопасности дорожного движения	Внесение изменений в ПДД, ужесточение требований к безопасности	- Необходимость постоянного обновления знаний о ПДД - Требования к соблюдению правил безопасности при перевозке различных видов грузов - Усиление контроля за соблюдением ПДД	- Знание актуальных правил дорожного движения - Навыки безопасного вождения - Знание правил перевозки различных видов грузов (опасных, скоропортящихся и т.д.)
2.2. Законодательство в области охраны окружающей среды	Ужесточение экологических стандартов для автотранспорта	- Требования к использованию экологически чистых видов транспорта - Необходимость соблюдения экологических норм и правил при эксплуатации автотранспорта - Знание способов снижения выбросов вредных веществ	- Знание экологических стандартов (Евро-5, Евро-6) - Умение экономить топливо и снижать выбросы CO₂ - Навыки использования экологически чистых видов топлива
2.3. Таможенное законодательство и международные соглашения	Изменения в правилах таможенного оформления грузов	- Требования к знанию правил таможенного оформления грузов - Необходимость владения иностранным языком (для международных перевозок) - Умение работать с таможенной документацией	- Знание таможенного законодательства - Владение иностранным языком (английским, немецким, китайским) - Навыки оформления таможенных документов
2.4. Трудовое законодательство	Изменения в правилах труда и отдыха водителей	- Требования к соблюдению режима труда и отдыха - Необходимость использования тахографов и других приборов контроля за режимом труда и отдыха	- Знание трудового законодательства (в части, касающейся режима труда и отдыха водителей) - Умение работать с тахографом
3. Потребительские предпочтения			
3.1. Рост электронной коммерции	Увеличение объемов онлайн-заказов и доставка «до двери»	- Требования к скорости и надежности доставки - Необходимость работы с различными типами грузов и упаковки - Важность коммуникации с клиентами	- Навыки быстрой и аккуратной доставки - Умение работать с различными типами грузов и упаковки - Коммуникабельность, вежливость
3.2. Повышение требований к качеству обслуживания	Требования к коммуникативным навыкам, предоставлению информации о статусе доставки	- Необходимость установления контакта с клиентом - Умение разрешать конфликтные ситуации — Предоставление информации о статусе доставки в режиме реального времени	- Коммуникабельность, вежливость - Умение разрешать конфликтные ситуации - Навыки использования мобильных приложений для связи с клиентами
3.3. Требования к экологичности и устойчивости	Повышение спроса на экологически чистый транспорт и «зеленую» логистику	- Требования к использованию экологически чистого транспорта - Важность учета социальных и этических аспектов деятельности	- Знание экологических стандартов и требований к устойчивому развитию - Умение экономить топливо и снижать выбросы CO₂ - Знание основ социальной ответственности бизнеса

Источник: выполнено Ю.О. Глушковой

Table 2

**Factors determining the dynamics of professional requirements for specialists
in the operation of motor transport in the field of transport and logistics services**

Factor	Description	Impact on professional requirements	Required competencies
1. Technological innovation			
1.1. Automation and digitalization	Implementation of TMS, WMS, ERP, ADAS, unmanned vehicles (in the future)	- The need to work with digital control systems - Requirements for data analysis and decision-making based on them - Changing the role of the driver (system monitoring, remote control)	- Digital literacy (working with TMS, WMS, ERP) - Skills in working with analytical tools - Knowledge of ADAS principles - Willingness to work with unmanned vehicles
1.2. Alternative fuels and electric vehicles	Transition to electric vehicles, hybrids, and gas-powered fuels	- Knowledge of the operation and maintenance of alternative modes of transport - Requirements for compliance with safety regulations when working with electrical and gas equipment - Knowledge of environmental standards	- Knowledge of the design and operating principles of alternative modes of transport - Skills in safe operation and maintenance of electric and gas-fueled vehicles - Knowledge of environmental legislation
1.3. The use of Big Data and analytics	Collecting and analyzing data on the operation of vehicles, road conditions, and driver behavior	- Requirements for data analysis and decision-making based on them - The need to use analytical tools to optimize routes, reduce costs and increase security	- Database skills - Ability to use analytical tools (Excel, Power BI, Python) - Knowledge of the basics of statistics and mathematical modeling
1.4. Internet of Things (IoT)	Using sensors and sensors to monitor cargo and vehicle conditions	- Requirements for working with sensor networks and data coming from sensors - The need for rapid response to changes in cargo parameters or vehicle condition	- Knowledge of the principles of operation of sensors and sensors - Ability to interpret data coming from sensors - Operational decision-making skills
2. Changes in legislation			
2.1. Rules of the road and road safety	Amendments to traffic regulations, stricter safety requirements	- The need for constant updating of knowledge about traffic regulations - Requirements for compliance with safety rules when trans-orting various types of goods - Strengthening control over compliance with traffic regulations	- Knowledge of current traffic rules - Safe driving skills - Knowledge of the rules of transportation of various types of goods (dangerous, perishable, etc.)
2.2. Legislation in the field of environmental protection	Stricter environmental standards for vehicles	- Requirements for the use of environmentally friendly modes of transport - The need to comply with environmental standards and regulations when operating vehicles - Knowledge of ways to reduce emissions of harmful substances	- Knowledge of environmental standards (Euro-5, Euro-6) - Ability to save fuel and reduce CO₂ emissions - Skills in using environmentally friendly fuels
2.3. Customs legislation and international agreements	Changes in the rules of customs clearance of goods	- Requirements for knowledge of the rules of customs clearance of goods - The need to speak a foreign language (for international transportation) - The ability to — work with customs documentation	- Knowledge of customs legislation - Foreign language proficiency (English, German, Chinese) - Customs clearance skills
2.4. Labor legislation	Changes in the rules of work and rest for drivers	- Requirements for compliance with the work and rest regime - The need to use tachographs and other devices for monitoring the work and rest regime	- Knowledge of labor legislation (in terms of the work and rest regime for drivers) - The ability to work with a tachograph
3. Consumer preferences			
3.1. The growth of e-commerce	The increase in online orders and door-to-door delivery	- Requirements for speed and reliability of delivery - The need to work with different types of goods and packaging - The importance of communication with customers	- Skills of fast and accurate delivery - The ability to work with different types of goods and packaging - Sociability, courtesy
3.2. Improving the quality of service	Requirements for communication skills, providing information about the delivery status	- The need to establish contact with the customer - The ability to resolve conflict situations - Providing information about the delivery status in real time	- Sociability, courtesy - The ability to resolve conflict situations - Skills in using mobile applications to communicate with customers
3.3. Requirements for environmental friendliness and sustainability	Increasing demand for environmentally friendly transport and “green” logistics	- Requirements for the use of environmentally friendly transport - The importance of taking into account the social and ethical aspects of activities	- Knowledge of environmental standards and requirements for sustainable development - The ability to save fuel and reduce CO₂ emissions - Knowledge of the basics of social responsibility of business

Source: by Yu.O. Glushkova

Таким образом, в табл. 2 представлена систематизация основных факторов, определяющих динамику профессиональных требований к специалистам по эксплуатации автомобильного транспорта в сфере ТЛИУ.

Перечень компетенций не является исчерпывающим и может быть дополнен в зависимости от конкретных требований работодателя и специфики деятельности. Важно учитывать взаимосвязь между различными факторами и их комплексное влияние на профессиональные требования.

Данная таблица может быть использована в качестве основы для разработки и корректировки образовательных программ подготовки

специалистов по эксплуатации автомобильного транспорта. Под специалистами по эксплуатации автомобильного транспорта подразумеваются как водители, так и специалисты по организации перевозок, логисты, механики и другие работники автотранспортных предприятий [14].

Следует отметить, что конкретные требования к компетенциям могут различаться в зависимости от уровня квалификации специалиста (например, водитель, техник, инженер) [12].

Для того чтобы представить или разработать методику учета факторов при формировании образовательных программ, необходимо включить этапы, представленные в табл. 3.

Таблица 3

Методика учета факторов при формировании образовательных программ

Этап	Содержание	Методы реализации	Ожидаемые результаты
1. Анализ факторов (определение и оценка влияния)	Определение ключевых факторов, оказывающих наибольшее влияние на профессиональные требования. Оценка степени влияния каждого фактора на компетенции (знания, умения, навыки, личностные качества)	- Анализ нормативных документов, исследований рынка труда, отчетов отраслевых организаций - Экспертные опросы и интервью с представителями автотранспортных предприятий, логистических компаний, образовательных учреждений - SWOT-анализ для оценки влияния факторов на сильные и слабые стороны системы подготовки кадров	- Сформированный перечень ключевых факторов, определяющих динамику профессиональных требований - Оценка степени влияния каждого фактора на формирование компетенций - Прогноз развития факторов в краткосрочной и долгосрочной перспективе
2. Формирование профиля компетенций (определение необходимых компетенций и уровней владения)	Определение перечня компетенций, необходимых специалистам по эксплуатации автомобильного транспорта, с учетом выявленных факторов. Определение требуемых уровней владения компетенциями в зависимости от должности и функциональных обязанностей (начальный, средний, продвинутый, экспертный)	- Разработка матрицы компетенций, сопоставляющей факторы, компетенции и уровни владения - Использование профессиональных стандартов, ФГОС, лучших мировых практик - Консультации с работодателями и профессиональными ассоциациями.	- Сформированный профиль компетенций, включающий перечень необходимых компетенций и требуемые уровни владения для каждой компетенции - Классификация компетенций по группам (технические, операционные, управленческие, социальные, личностные) - Определение компетенций, требующих приоритетного развития
3. Разработка учебного плана и программ (формирование дисциплин, разработка материалов, внедрение методов обучения)	Формирование учебного плана, включающего дисциплины и модули, направленные на формирование компетенций. Разработка учебных материалов, учитывающих современные технологические достижения и требования рынка труда. Внедрение современных методов обучения (практико-ориентированное обучение, дистанционное обучение, проектное обучение, преподавание на основе данных)	- Разработка модульных образовательных программ, основанных на компетенциях - Использование активных и интерактивных методов обучения (кейсы, деловые игры, тренинги, симуляции) - Привлечение практиков к преподаванию и проведению мастер-классов - Создание онлайн-курсов и образовательных платформ - Разработка системы оценки результатов обучения, основанной на компетенциях	- Разработанный учебный план, включающий перечень дисциплин и модулей, направленных на формирование необходимых компетенций - Разработанные учебные материалы, учитывающие современные технологические достижения - Внедрение современных методов обучения, повышающих эффективность учебного процесса
4. Оценка и контроль качества (разработка системы оценки, мониторинг результатов, корректировка программ)	Разработка системы оценки компетенций, включающей различные методы и инструменты (тестирование, практические задания, защита проектов, аттестация, оценка по принципу «360 градусов»). Мониторинг и анализ результатов обучения, корректировка образовательных программ	- Разработка критериев оценки компетенций - Создание банка оценочных средств - Проведение промежуточной и итоговой аттестации - Анализ успеваемости студентов и отзывов работодателей - Использование статистических методов для анализа результатов обучения	- Разработанная система оценки компетенций, позволяющая объективно оценить уровень подготовки специалистов - Своевременное выявление проблемных зон в учебном процессе. - Корректировка образовательных программ и учебных материалов на основе результатов мониторинга и анализа
5. Взаимодействие с работодателями (опросы, привлечение практиков, организация стажировок, участие в разработке программ)	Проведение опросов и консультаций с работодателями для выявления их потребностей в компетенциях специалистов. Привлечение практиков к преподаванию. Организация стажировок и практик на предприятиях. Участие работодателей в разработке и экспертизе образовательных программ	- Заключение договоров о сотрудничестве с предприятиями - Организация круглых столов и семинаров с участием работодателей - Создание наблюдательных советов с участием представителей работодателей - Организация конкурсов профессионального мастерства	- Учет потребностей работодателей при формировании образовательных программ - Повышение практической направленности обучения - Улучшение трудоустройства выпускников

Источники: выполнено Ю.О. Глушковой

Table 3

Methodology for taking into account factors in the formation of educational programs

Stage	Content	Implementation methods	Expected results
1. Factor analysis (identification and assessment of impact)	Identify the key factors that have the greatest impact on professional requirements. Assessment of the degree of influence of each factor on competencies (knowledge, skills, personal qualities)	• Analysis of regulatory documents, labor market research, and reports from industry organizations • Expert surveys and interviews with representatives of trucking companies, logistics companies, and educational institutions • SWOT analysis to assess the impact of factors on the strengths and weaknesses of the training system	• A list of key factors determining the dynamics of professional requirements has been formed • Assessment of the degree of influence of each factor on the formation of competencies — Forecast of the development of factors in the short and long term
2. Formation of a competence profile (determination of required competencies and proficiency levels)	Determination of the list of competencies required by specialists in the operation of motor transport, taking into account the identified factors. Determining the required levels of competence depending on the position and functional responsibilities (beginner, intermediate, advanced, expert)	• Development of a competence matrix comparing factors, competencies and proficiency levels • The use of professional standards, the Federal State Educational Standard, and the best international practices • Consultations with employers and professional associations	• A developed competence profile, including a list of required competencies and required proficiency levels for each competence • Classification of competencies into groups (technical, operational, managerial, social, personal) • Identification of competencies requiring priority development
3. Development of the curriculum and programs (formation of disciplines, development of materials, implementation of teaching methods)	Formation of a curriculum that includes disciplines and modules aimed at building competencies. Development of educational materials that take into account modern technological advances and labor market requirements. Implementation of modern teaching methods (practice-based learning, distance learning, project-based learning, data-based teaching)	• Development of modular educational programs based on competencies • The use of active and interactive teaching methods (cases, business games, trainings, simulations) • Involvement of practitioners in teaching and conducting master classes • Creation of online courses and educational platforms • Development of a competency-based learning outcome assessment system	• A developed curriculum that includes a list of disciplines and modules aimed at developing the necessary competencies — Developed educational materials that take into account modern technological advances. • The introduction of modern teaching methods that increase the effectiveness of the educational process.
4. Evaluation and quality control (development of an evaluation system, monitoring of results, program adjustments)	Development of a competence assessment system that includes various methods and tools (testing, practical tasks, project protection, certification, 360-degree assessment). Monitoring and analysis of learning outcomes, adjustment of educational programs	• Development of competence assessment criteria • Creation of a bank of appraisal funds • Conducting intermediate and final attestation • Analysis of student performance and employer reviews • The use of statistical methods to analyze learning outcomes	• A developed competence assessment system that allows an objective assessment of the level of training of specialists • Timely identification of problem areas in the educational process • Adjustment of educational programs and teaching materials based on the results of monitoring and analysis
5. Interaction with employers (surveys, recruitment of practitioners, organization of internships, participation in the development of programs)	Conducting surveys and consultations with employers to identify their needs for specialist competencies. Involvement of practitioners in teaching. Organization of internships and internships at enterprises. The participation of employers in the development and examination of educational programs	• Conclusion of cooperation agreements with enterprises • Organization of round tables and seminars with the participation of employers • Creation of supervisory boards with the participation of representatives of employers • Organization of professional skills competitions	• Taking into account the needs of employers when forming educational programs • Increasing the practical orientation of training • Improving the employment of graduates

Source: by Yu.O. Glushkova

Таким образом, при применении данной методики используется комплексный подход, так как учитываются все этапы процесса подготовки кадров, от анализа до оценки результатов. Также следует отметить компетентностный подход, который ориентирован на формирование конкретных компетенций, необходимых для успешной профессиональной деятельности [13].

Активное использование практических методов обучения и взаимодействие с работодателями придает методике практическую направленность.

Необходимо регулярно проводить мониторинг и корректировку образовательных программ на основе результатов и обратной связи, таким образом совершенствовать методику учета факторов при формировании образовательных программ, а также быстро адаптироваться к меняющимся требованиям рынка труда и технологическим инновациям [15].

Применение данной методики позволит формировать образовательные программы, отвечающие современным требованиям сферы транспортно-логистических услуг и обеспечивающие подготовку высококвалифицированных

специалистов, способных эффективно решать сложные задачи в условиях динамично меняющейся среды [16]. Необходимо отметить, что предложенная методика позволяет учитывать динамику профессиональных требований к специалистам по эксплуатации автомобильного транспорта в сфере транспортно-логистических услуг при формировании образовательных программ [14]. Ее реализация способствует повышению качества подготовки кадров, улучшению соответствия выпускников требованиям рынка труда и повышению эффективности работы автотранспортных предприятий [18]. Регулярный мониторинг и анализ факторов, а также взаимодействие с работодателями являются ключевыми элементами успешной реализации методики [17].

3. Результаты и обсуждение

Поставленная задача в работе выполнена: представлен комплекс профессиональных компетенций, необходимых специалистам по эксплуатации автомобильного транспорта для соответствия современным требованиям сферы транспортно-логистических услуг, и разработаны практические рекомендации по совершенствованию системы кадров, направленные на повышение эффективности функционирования автотранспортных предприятий.

Таким образом, проанализированы факторы, влияющие на профессиональные требования (технологические инновации, изменения законодательства, потребительские предпочтения). Также в работе систематизированы виды компетенций (профессиональные, ИТ-навыки, управленческие и др.) и их влияние на эффективность ТЛУ. На основе этого разработана методика учета факторов при создании образовательных программ, включающая этапы анализа, формирования профиля компетенций, разработки учебных планов, оценки качества и взаимодействия с работодателями.

Представлено изложение новых научных результатов, полученных автором :

1. Выявлена взаимосвязь между развитием цифровых технологий (TMS, IoT, Big Data) и ростом требований к ИТ-компетенциям специалистов.

2. Предложена классификация компетенций, адаптированная к современным вызовам ТЛС, включая навыки работы с альтернативными видами транспорта и экологическими стандартами.

3. Разработана практико-ориентированная методика формирования образовательных программ, основанная на регулярном мониторинге факторов и обратной связи от работодателей.

4. Обоснована необходимость интеграции «гибких» навыков (коммуникация, адаптивность) в профессиональную подготовку для повышения конкурентоспособности выпускников.

Заключение

Результаты исследования подчеркивают важность непрерывного обновления образовательных стандартов и активного сотрудничества учебных заведений с отраслевыми предприятиями для подготовки кадров, отвечающих запросам цифровой экономики.

Компетенции являются ключевым фактором, определяющим профессиональные требования в транспортно-логистической сфере. Цифровизация, глобализация, изменение потребительских ожиданий и другие факторы предъявляют новые требования к квалификации специалистов, требуя от них обладания широким спектром компетенций — от профессиональных знаний в области логистики и управления цепочками поставок до навыков работы с современными ИТ-системами и развитых «гибких» навыков.

Для успешной карьеры в сфере ТЛС необходимо постоянно развивать свои компетенции, следить за новыми тенденциями в отрасли и адаптироваться к меняющимся требованиям рынка труда. Инвестиции в развитие компетенций являются важным условием для повышения конкурентоспособности и достижения успеха в этой динамично развивающейся отрасли.

Список литературы

1. Кристофер М. Логистика и управление цепочками поставок: как сократить затраты и улучшить обслуживание потребителей. Москва : Питер, 2004. 315 с. ISBN 5-94723-168-9 EDN: QQECNN
2. Boyatzis R.E. The competent manager: a model for effective performance. New York : Wiley, 1982. 332 p. URL: <https://archive.org/details/competentmanager0000boya> (accessed: 15.03.2025).
3. Spencer L.M., Spencer S.M. Competence at work: models for superior performance. New York : Wiley Publ.; 1993. URL: <https://archive.org/details/competenceatwork00spen> (accessed: 06.05.2025).
4. McClelland D.C., Winter D.G., Larrere J., Nathan M. Identifying competencies with behavioral-event interviews // *Psychological science*. 1998. Vol. 9. Issue 5. P. 331–339. <http://doi.org/10.1111/1467-9280.00065>
5. Benner P., Tanner C., Chesla C. From beginner to expert // *Advances in Nursing Science*. 1992. Vol. 14. Issue 3. P. 13–28. <http://doi.org/10.1097/00012272-199203000-00005>
6. Rushton A., Croucher Ph., Baker P. The Handbook of Logistics and Distribution Management: Understanding the Supply Chain. 5th Kogan Page, 2014. 720 p. ISBN 9780749466275
7. Simchi-Levi D., Kaminsky P., Simchi-Levi E. Supply chain design and management: concepts, strategies, and case studies // *Journal of Business Logistics*. 2008. Vol. 22. No. 1. P. 259–261. <http://doi.org/10.1002/j.2158-1592.2001.tb00165.x>
8. Андриухин Д.В. Логистическая отрасль в современных экономических условиях // Актуальные вопросы экономики : сборник статей XVII Международной научно-практической конференции, Пенза, 25 апреля 2024 года. 2024. С. 65–70. EDN: SIBXFG
9. Базаров Т.Ю., Ерофеев А.К., Шмелев А.Г. Коллективное определение понятия «компетенции»: попытка извлечения смысловых тенденций из размытого экспертного знания // Вестник Московского университета. Серия 14: Психология. 2014. № 1. С. 87–102. EDN: RXQFTT
10. Vaičiūtė K., Skirmantienė J., Domanska L. Assessment of transport specialists' competencies in transport/logistics companies // *Procedia Engineering*. 2017. Vol. 187. P. 628–634. <http://doi.org/10.1016/j.proeng.2017.04.423>
11. Овчинников А.В. Универсальная модель профессиональных компетенций // Наукovedenie. 2014. № 4 (23). С. 1–11. URL: <https://naukovedenie.ru/PDF/100EVN414.pdf> (дата обращения: 20.03.2025).
12. Waters C.D.J. Supply chain management: an introduction to logistics. New York : Palgrave Macmillan Publ.; 1949. 548 p. URL: <https://archive.org/details/supplychainmanag0000wate> (accessed: 15.03.2025).
13. Chopra S., Meindl P. Supply Chain Management: Strategy, Planning and Operation. 5th ed. New Jersey : Pearson Education, 2013. 529 p. ISBN 9780132743952

14. Lin C.-Ch., Chang Ch.-H. Evaluating skill requirement for logistics operation practitioners: based on the perceptions of logistics service providers and academics in Taiwan // *The Asian Journal of Shipping and Logistics*. 2018. Vol. 34. Issue 4. P. 328–336. <http://doi.org/10.1016/j.ajsl.2018.12.006>

15. Залетов Ю.С. Развитие профессиональной подготовки работников транспортно-логистической отрасли для повышения эффективности их работы (на примере программы подготовки «Менеджер внешне-экономической деятельности» для специалистов экономического профиля предприятий региона) // Вестник Московского финансово-юридического университета МФЮА. 2018. № 1. С. 245–255. EDN: UNYWFU

16. Овчинников А.В. Корпоративное образование: предел риска // Корпоративные университеты. 2014. № 49. С. 18–24.

17. Prahalad C.K., Hamel G. the core competence of the corporation // *Harvard Business Review*. 1990. Vol. 68. P. 275–292. http://doi.org/10.1007/3-540-30763-X_14

18. Sokal R.R. Cluster analysis and classification: prerequisites and main directions // *Proceedings of an advanced seminar conducted by the Mathematics Research Center, the University of Wisconsin. Madison, May 3–5, New York: Academic Press; 1976. P. 1–16. ISBN 100127142509*

References

1. Christopher M. *Logistics and Supply chain management: how to reduce costs and improve customer service*. Peter. 2004. (In Russ.) ISBN 5-94723-168-9 EDN: QQECNN
2. Boyatzis RE. *The competent manager: a model for effective performance*. New York : Wiley, 1982. Available from: <https://archive.org/details/competentmanager0000boya> (accessed: 15.03.2025).
3. Spencer LM, Spencer SM. *Competence at work: models for superior performance*. New York: Wiley Publ.; 1993. Available from: <https://archive.org/details/competenceatwork00spen> (accessed: 06.05.2025).
4. McClelland DC, Winter DG, Larrere J, Nathan M. Identifying competencies with behavioral-event interviews. *Psychological science*. 1998;9(5):331–339. <http://doi.org/10.1111/1467-9280.00065>
5. Benner P, Tanner C, Chesla C. From beginner to expert. *Advances in Nursing Science*. 1992;14(3):13–28. <http://doi.org/10.1097/00012272-199203000-00005>
6. Rushton A, Croucher Ph, Baker P. The Handbook of Logistics and Distribution Management: Understanding the Supply Chain. 2014. ISBN 9780749466275
7. Simci-Levi D, Kaminski P, Simci-Levi E. Supply chain design and management: concepts, strategies, and case studies. *Journal of Business Logistics*. 2008;22(1): 259–261. <http://doi.org/10.1002/j.2158-1592.2001.tb00165.x>
8. Andriukhin DV. *Logistics industry in modern economic conditions*. Penza: Actual issues of economics. 2024;65–70. (In Russ.) EDN: SIBXFG

9. Bazarov TYu, Erofeev AK, Shmelev AG. Collective definition of the notion “Competence”: an attempt to acquire semantic regularities from fuzzy expert knowledge. *Moscow University Psychology Bulletin*. 2014;(1):87–102. (In Russ.) EDN: RXQFTT
10. Vaičiūtė K, Skirmantienė J, Domanska L. Assessment of transport specialists’ competencies in transport/logistics companies. *Procedia Engineering*. 2017;187: 628–634. <http://doi.org/10.1016/j.proeng.2017.04.423>
11. Ovchinnikov AV. Universal model of professional competencies. *Science studies*. 2014;(4):1–11. (In Russ.) EDN: TCFNIH
12. Waters CDJ. *Supply chain management: an introduction to logistics*. New York : Palgrave Macmillan Publ.; 1949. Available from: <https://archive.org/details/supply-chain-manag0000wate> (accessed: 15.03.2025).
13. Chopra S, Meindl P. Supply chain management: strategy, planning and operation. Pearson Education. *American Journal of Industrial and Business Management*. 2016;12(3).
14. Lin C-Ch, Chang Ch-H. Evaluating skill requirement for logistics operation practitioners: based on the perceptions of logistics service providers and academics in Taiwan. *The Asian Journal of Shipping and Logistics*. 2018;34(4):328–336. <http://doi.org/10.1016/j.ajsl.2018.12.006>
15. Zaletov YuS. Improvement of vocational training of employees in the transport and logistics sector of the regional economy for increase efficiency their work (by the example of the training program “Manager of foreign economic activity” for specialists in the economic realm of enterprises of the region). *Herald of the Moscow university of finances and law MFU*. 2018;(1):245–255. (In Russ.) EDN: UNYWFU
16. Ovchinnikov AV. Corporate education: the limit of risk. *Corporate universities*. 2014;49:18–24. (In Russ.)
17. Prahalad CK, Hamel G. The core competence of the corporation. *Harvard Business Review*. 1990;68: 275–292. http://doi.org/10.1007/3-540-30763-X_14
18. Sokal RR. Cluster analysis and classification: prerequisites and main directions. *Proceedings of an advanced seminar conducted by the Mathematics Research Center, the University of Wisconsin*. Madison, May 3–5, New York: Academic Press; 1976. P. 1–16. ISBN 100127142509

Сведения об авторах

Глушкова Юлия Олеговна, кандидат экономических наук, доцент кафедры техники и технологии транспорта, инженерная академия, Российский университет дружбы народов, Российская Федерация, 117198, г. Москва, ул. Миклухо-Маклая, д. 6; eLIBRARY SPIN-код: 3400-0298, ORCID: 0000-0001-6793-2441; e-mail: glushkova_yuo@pfur.ru

Мнацаканян Виктория Умедовна, доктор технических наук, профессор кафедры горного оборудования, транспорта и машиностроения, Национальный исследовательский технологический университет «МИСИС», Российская Федерация, 119049, г. Москва, Ленинский проспект, д. 4, стр. 1; eLIBRARY SPIN-код: 8693-8313, ORCID: 0000-0001-9276-7599; e-mail: artvik@bk.ru

About the authors

Yulia O. Glushkova, PhD in Economics, Associate Professor of the Department of Engineering and Transport Technology, Engineering Academy, RUDN University, 6 Miklukho-Maklaya St, Moscow, 117198, Russian Federation; eLIBRARY SPIN-code: 3400-0298, ORCID: 0000-0001-6793-2441; e-mail: glushkova_yuo@pfur.ru

Victoria U. Mnatsakanyan, Doctor of Technical Sciences, Professor of the Department of Mining Equipment, Transport and Mechanical Engineering, National Research Technological University “MISIS”, Bld. 1, 4, Leninsky Prospekt, Moscow, 119049, Russian Federation; eLIBRARY SPIN-code: 8693-8313, ORCID: 0000-0001-9276-7599; e-mail: artvik@bk.ru